

## EVALUASI PERBANDINGAN PERFORMANSI LVQ 1, LVQ 2, DAN LVQ 3 DALAM KLASIFIKASI JENIS KELAMIN MENGUNAKAN TULANG TENGGORAK

DARMILA<sup>1\*</sup>, IIS AFRIANTY<sup>2</sup>, SUWANTO SANJAYA<sup>3</sup>, RAHMAD  
ABDILLAH<sup>4</sup>, IWAN ISKANDAR<sup>5</sup>, FADHILAH SYAFRIA<sup>6</sup>

<sup>1,2,3,4,5,6</sup> Program Studi Teknik Informatika, Fakultas Sains dan Teknologi  
Universitas Islam Negeri Sultan Syarif Kasim Riau

Jl. H.R Soebrantas No 155 KM.15 Simpang Baru Panam Pekanbaru, 28293

Email: <sup>1</sup>11850120401@students.uin-suska.ac.id, <sup>2</sup>iis.afrianty@uin-suska.ac.id,  
<sup>3</sup>suwantosanjaya@uin-suska.ac.id, <sup>4</sup>rahmad.abdillah@uin-suska.ac.id,  
<sup>5</sup>iwan.iskandar@uin-suska.ac.id, <sup>6</sup>fadhilah.syafria@uin-suska.ac.id

### ABSTRAK

Klasifikasi merupakan teknik pengelompokan data sesuai dengan karakteristik data yang telah ditentukan. Hasil performansi akurasi dapat menjadi ukuran keakuratan metode yang digunakan dalam proses klasifikasi. Teknik pengambilan data yang tidak sesuai dapat mengurangi hasil akurasi. Pada penelitian ini menggunakan metode *Learning Vector Quantization* (LVQ) 1, 2, dan 3 untuk melihat keakuratan metode klasifikasi dengan menggunakan teknik pengambilan data *sampling*. Data yang digunakan merupakan data pengukuran tulang tengkorak laki-laki dan perempuan yang berjumlah 2524 data. Pada LVQ 1 mendapatkan akurasi terbaik yaitu 91.39% dengan *learning rate* 0.1, 0.4, 0.7, 0.9. LVQ 2 mendapatkan akurasi terbaik 77.05% dengan *learning rate* 0.9 dan *window* 0.2. LVQ 3 mendapatkan akurasi terbaik yaitu 80.04% dengan *learning rate* 0.7, *window* 0.1, dan *epsilon* 0.3. Hal ini menunjukkan bahwa LVQ 1 lebih tepat untuk diterapkan terhadap multi-fitur pada *dataset* William W. Howells *Craniometric* dibandingkan LVQ 2 dan LVQ 3.  
Kata Kunci : Akurasi, klasifikasi, LVQ, tulang, tengkorak

### I. PENDAHULUAN

Klasifikasi (Bishop, 2006) merupakan teknik dalam mengelompokkan obyek yang terdapat dalam sebuah kelompok, kelas, dan kategori melalui karakteristik yang telah ditentukan. Teknik klasifikasi biasa digunakan untuk memprediksikan data set dengan kategori biner dan nominal (Wibawa et al., 2018). Penelitian tentang klasifikasi telah banyak diterapkan. Salah satunya adalah antropologi pada bidang forensik yang berguna dalam merekonstruksi dan menggambarkan sketsa biologis individu yang tidak dikenal. Informasi yang diperoleh dari hasil identifikasi dapat bermanfaat untuk

kasus kematian seperti tindakan kriminalitas. Salah satu cara identifikasi yang cukup umum adalah dengan cara menentukan jenis kelamin.

Dalam menentukan jenis kelamin dibutuhkan data tulang yang dianalisis dengan metrik dan pengukuran morfologi (Fukuta et al., 2020). Tulang tengkorak menjadi salah satu bagian kerangka yang bisa digunakan untuk menentukan jenis kelamin dan termasuk tulang terbaik setelah tulang panggul (Toneva et al., 2021). Dalam penelitian ini data tengkorak digunakan berdasarkan 82 pengukuran metrik yang menjadi fitur dalam menentukan jenis kelamin.

Teknik klasifikasi yang paling sering digunakan pada penentuan jenis kelamin adalah *Discriminant Function Analysis* (DFA) oleh (Omar et al., 2021), dan *Logistic Regression* (LR) oleh (Bidmos et al., 2021). Dalam beberapa tahun terakhir, identifikasi jenis kelamin juga diterapkan menggunakan *Machine Learning* (ML) (Toneva et al., 2021). Salah satu teknik ML yang paling sering digunakan dalam klasifikasi jenis kelamin yaitu *Artificial Neural Networks* (ANN) atau lebih dikenal dengan Jaringan Syaraf Tiruan (Oner et al., 2019).

Metode klasifikasi yang digunakan pada penelitian ini yaitu *Learning Vector Quantization* (LVQ) yang merupakan cabang ilmu Jaringan Syaraf Tiruan. Dalam perkembangannya metode LVQ terbagi menjadi beberapa jenis yaitu LVQ 1, LVQ 2, LVQ 2.1, dan LVQ 3. Algoritma ini diperkenalkan oleh Teuvo Kohonen. LVQ adalah algoritma Jaringan Syaraf Tiruan pada pembelajaran lapisan kompetisi yang terawasi (Kohonen, 1988).

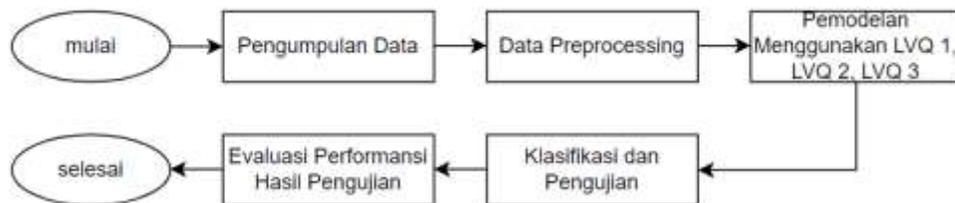
Penerapan LVQ 1 yang pernah dilakukan adalah klasifikasi Leukimia Akut (ALL dan AML) (Asadi et al., 2019) dengan menggunakan ekstraksi citra pada sel darah. Adapun hasil akurasi yang dihasilkan yaitu 93,3%. Pada penelitian lain dengan menggunakan metode LVQ 2 pada klasifikasi gangguan kehamilan trimester 1 (Budianita et al., 2018) mencapai akurasi yang sempurna yaitu 100%. Pada penerapan LVQ 3 yaitu klasifikasi status gizi pada lansia (Muzaqi et al., 2022) dengan capaian hasil akurasi tertinggi yaitu 86,67%.

Pemilihan teknik penelitian yang tepat bisa memberikan hasil akurasi yang maksimal. Pada penelitian tentang pengaruh ketidakseimbangan kelas pada klasifikasi LVQ (Abdillah et al., 2018) menggunakan teknik *sampling* dalam pengambilan data sampel dengan menggunakan dataset NSL-KDD yang berjumlah 125973 data. Hasil penelitian menunjukkan bahwa proses distribusi data dan teknik pengambilan data yang tepat bisa memengaruhi keakuratan hasil akurasi menjadi lebih baik.

Pada penelitian ini, akan dilakukan penelitian mengenai peningkatan performansi akurasi menggunakan algoritma *Learning Vector Quantization* (LVQ) pada *dataset* William White Howells Craniometric. *Dataset* William W. Howells *Craniometric* (Auerbach, n.d.) merupakan kumpulan data pengukuran tempurung kepala manusia (tengkorak) yang diukur oleh Dr. William Howells yang disusun dari tahun 1965 hingga 1980. *Dataset* ini berjumlah 2524 data dan 86 fitur. Kontribusi pada penelitian ini adalah mengevaluasi performansi algoritma LVQ 1, 2, dan 3 terhadap multi-fitur pada *dataset* dengan menerapkan *sampling* dalam pengambilan data dan menganalisis hasil akurasi berdasarkan parameter-parameter pengujian yang digunakan.

## II. METODE PENELITIAN

Penelitian ini terdiri dari 5 tahapan seperti pada Gambar 1 berikut:



Gambar 1. Kerangka Kerja Penelitian

Berdasarkan kerangka kerja penelitian pada Gambar 1, adapun tahapan penelitian dapat diuraikan sebagai berikut:

### 1. Pengumpulan Data

Tulang tengkorak dapat digunakan untuk menentukan jenis kelamin manusia.

Data yang digunakan pada penelitian ini terdiri dari 1368 data tengkorak laki-laki dan

1156 data tengkorak perempuan. Ada 82 fitur pengukuran tengkorak manusia. Pada Tabel 1 dan Tabel 2 di bawah ini menunjukkan 10 fitur dari 82 fitur pengukuran tulang tengkorak dengan kode masing-masing.

Tabel 1. Sepuluh Fitur Pengukuran Tengkorak

Kode	Fitur Dalam Pengukuran Tulang Tengkorak
<b>GOL</b>	Glabello-occipital length
<b>BNL</b>	Basion-nasion length
<b>BPL</b>	Basion-prosthion length
<b>ZYB</b>	Bizygomatic breadth
<b>FOL</b>	Foramen magnum length
<b>NPH</b>	Nasion-prosthion height
<b>NLH</b>	Nasal height
<b>NLB</b>	Nasal breadth
<b>ZMB</b>	Bimaxillary breadth

Tabel 2. Pengukuran Tulang Tengkorak (MM)

Kelas	GOL	BNL	BPL	ZYB	FOL	NPH	NLH	NLB	ZMB	MAB	...	AUB
...	...	...	...	...	...	...	...	...	...	...	...	...
M	193	104	98	131	35	70	54	25	86	59	...	122
M	192	102	92	137	32	71	54	24	89	59	...	130
M	189	106	96	139	31	72	55	23	85	58	...	134
F	182	97	103	122	35	68	48	26	92	60	...	117
F	170	91	90	124	33	65	48	21	79	58	...	113
...	...	...	...	...	...	...	...	...	...	...	...	...
F	153	88	92	115	32	53	41	21	89	56	...	103

## 2. Data Preprocessing

Pada tahapan data *preprocessing* dilakukan *cleaning* data, transformasi data, normalisasi data, dan distribusi data.

### A. Cleaning Data

Pada *dataset* ini menghapus data pada fitur Population dan Popnum. Fitur tersebut dihapus karena tidak digunakan karena hanya menjelaskan populasi dan nama populasi.

### B. Transformasi Data

Pada penelitian ini melakukan transformasi pada kelas *male* dengan nilai 1, dan kelas *female* dengan nilai 2.

### C. Normalisasi Data

Penelitian ini melakukan proses normalisasi dengan metode min-max yaitu dengan menskalakan range fitur antara 0 dan 1. Normalisasi dilakukan dengan menggunakan Persamaan 1.

$$X_{new} = \left( \frac{X_{old} - X_{min}}{X_{max} - X_{min}} (new_{max} - new_{min}) \right) + new_{min} \quad (1)$$

### D. Distribusi Data

Distribusi data pada penelitian ini dibagi menjadi 9 sampel kelas dari masing-masing kelas. Pada Tabel 3 merupakan distribusi data yang akan digunakan pada saat pengujian. Pada kelas *male* menjelaskan jumlah data tulang tengkorak laki-laki dan pada kelas *female* menjelaskan jumlah data tulang tengkorak pada perempuan pada tiap *sampling* (SI – S IX).

Tabel 3. Data Sampling

Class	SI	SII	SIII	SIV	SV	SVI	SVII	SVIII	SIX
Male	1231	137	1094	274	958	410	821	547	684
Female	116	1040	231	925	347	809	462	694	578

### 3. Pemodelan Menggunakan LVQ 1, LVQ 2, LVQ 3

Pada tahap ini data-data yang diperlukan dimodelkan sesuai dengan tahap-tahap pada algoritma LVQ 1, LVQ 2, dan LVQ 3.

### 4. Klasifikasi dan Pengujian

Dalam proses klasifikasi dilakukan proses *training* dan *testing* menggunakan *dataset* yang telah diketahui kelas objeknya. Selain itu, juga dilakukan pengujian performansi dari LVQ 1, LVQ 2, dan LVQ 3.

### 5. Evaluasi Performansi Hasil Pengujian

Pada tahap ini yaitu mengevaluasi performansi dari LVQ 1, LVQ 2, dan LVQ 3 berdasarkan hasil pengujian yang telah dilakukan.

Penelitian ini menggunakan metode *Learning Vector Quantization* (LVQ) 1, 2, dan 3. Metode ini adalah salah satu metode klasifikasi berbasis Jaringan Syaraf Tiruan (JST) dengan konsep kompetisi, yang berarti ialah hanya ada satu *neuron* pemenang atau terpilih (Kohonen, 1990b).

### 2.1 LVQ 1

Algoritma LVQ 1 adalah dasar awal dari algoritma LVQ dimana hanya vektor referensi yang paling dekat dengan distribusi kelas yang akan diperbaharui (Kohonen, 1990a). Dalam pembelajaran pada LVQ 1 parameter yang digunakan yaitu:

1. Menentukan nilai vektor X, nilai target (T), nilai vektor bobot ( $W_j$ ), nilai kelas ( $C_j$ ), nilai *learning rate* ( $\alpha$ ) dengan ketentuan  $0 < \alpha < 1$ , nilai pengurangan atau penurunan *learning rate* ( $\alpha$ ), dan nilai *minimum learning rate* ( $\min \alpha$ )
2. Melakukan pembaruan nilai bobot apabila sesuai dengan kondisi:  
jika  $T=C_j$ , maka diselesaikan dengan Persamaan (2).

$$W_j(\text{baru}) = W_j(\text{lama}) + \alpha[X_i - W_j(\text{lama})] \quad (2)$$

jika  $T \neq C_j$ , maka diselesaikan dengan Persamaan (3).

$$W_j(\text{baru}) = W_j(\text{lama}) - \alpha[X_i - W_j(\text{lama})] \quad (3)$$

### 2.2 LVQ 2

Pada LVQ 2, vektor pemenang pertama dan vektor pemenang kedua akan sama-sama diperbaharui apabila kedua vektor mempunyai perkiraan jarak yang sama (Budianita et al., 2018). Adapun tahapan-tahapan pada LVQ 2 yaitu:

1. Menentukan nilai bobot  $w$  dan  $j$ , nilai *learning rate* ( $\alpha$ ) dan *window* ( $\varepsilon$ ).
2. Pada pelatihan vektor  $W$  temukan nilai  $j$ , agar  $|X_i - W_j|$  bernilai minimum
3. Memperbaiki nilai  $W_j$  dengan kondisi:
  - a.  $T = C_j$ , maka diselesaikan dengan Persamaan (2).
  - b.  $T \neq C_j$ , maka diselesaikan dengan Persamaan (4).

$$D_1 > (1 - \varepsilon) * D_2 \text{ AND } D_2 < (1 + \varepsilon) * D_1 \quad (4)$$

Jika True,  $W$  tidak termasuk vektor  $X$  diperbaharui dengan Persamaan (5).

$$Y_{C_j}(t + 1) = Y_{C_j}(t) - \alpha(t)[X(t) - Y_{C_j}(t)] \quad (5)$$

$W$  termasuk vektor  $X$  diperbaharui dengan Persamaan (6).

$$YC_j(t + 1) = YC_j(t) + \alpha(t)[X(t) - YC_j(t)] \quad (6)$$

- c. Diperoleh  $W_j$  baru, namun jika kondisi bernilai False diselesaikan dengan persamaan (2).
- d. Lakukan pengurangan  $\alpha$ .

### 2.3 LVQ 3

LVQ 3 dikembangkan untuk melakukan koreksi untuk memastikan nilai vektor perwakilan agar selalu berada dalam posisi mendekati distribusi kelas (Kohonen, 1990b) dan apabila kedua vektor referensi terdekat terletak pada sasaran kelas yang sama maka dapat dilakukan perubahan bobot. Adapun tahapan-tahapan pada LVQ 3 yaitu:

1. Menentukan nilai bobot  $W_j$ , nilai  $X$ , nilai target ( $T$ ), nilai *learning rate* ( $\alpha$ ) yaitu dengan nilai  $0 < \alpha < 1$ , nilai pengurangan  $\alpha$ , dan nilai  $\min \alpha$ .
2. Menentukan nilai *window* ( $\epsilon$ ) dengan menggunakan Persamaan (7).

$$\text{Min} \left( \frac{dc1}{dc2}, \frac{dc2}{dc1} \right) > (1 - \epsilon)(1 + \epsilon) \quad (7)$$

3. Apabila nilai *window* ( $\epsilon$ ) bernilai True (kondisi  $\epsilon$  tercapai), maka menggunakan Persamaan (8) dan Persamaan (9).

$$YC_1(t + 1) = YC_1(t) - \alpha(t)[x(t) - YC_1(t)] \quad (8)$$

$$YC_2(t + 1) = YC_2(t) + \alpha(t)[x(t) - YC_2(t)] \quad (9)$$

4. Apabila nilai *window* ( $\epsilon$ ) bernilai False (kondisi  $\epsilon$  tidak tercapai), maka menggunakan Persamaan (10) dan Persamaan (11).

$$YC_1(t + 1) = YC_1(t) - \beta(t)[x(t) - YC_1(t)] \quad (10)$$

$$YC_2(t + 1) = YC_2(t) + \beta(t)[x(t) - YC_2(t)] \quad (11)$$

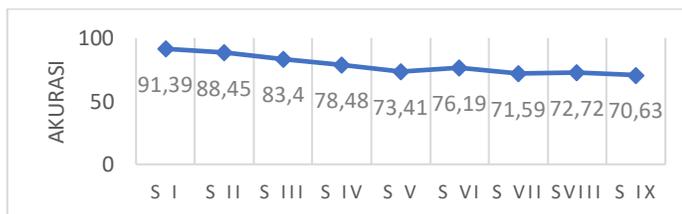
Setelah melakukan proses pelatihan maka didapatkan hasil bobot-bobot akhir ( $W$ ). Setelah mendapatkan bobot dari tiap-tiap  $w$ , selanjutnya dilakukan penentuan bobot terdekat, dan menetapkan nilai bobot kelas.

### III. HASIL DAN PEMBAHASAN

*Dataset* William dibagi menjadi data pelatihan dan pengujian yang dibuat dalam 9 sampel. Data tersebut diuji dengan menggunakan pengujian *k-fold cross validation* dengan menggunakan parameter nilai *learning rate* ( $\alpha$ ) 0.00001, 0.0001, 0.001, 0.01, 0.1, 0.4, 0.7, dan 0.9, *minimum*  $\alpha$  0.01, pengurang  $\alpha$  0.01, nilai *window* 0, 0.3, 0.4, 0.1, 0.5, dan 0.2 pada LVQ 2 dan 3, dan nilai epsilon 0.1, 0.2, 0.3, 0.5 pada LVQ 3. Adapun nilai *epoch* yang digunakan yaitu 1000.

### 3.1 LVQ 1

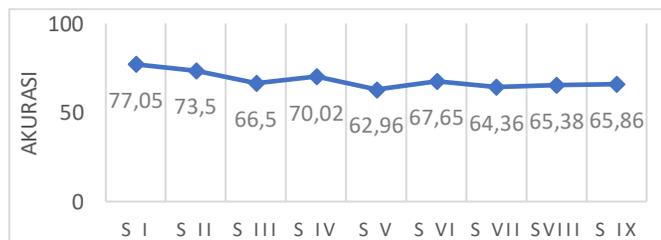
Pada LVQ 1 pencapaian akurasi tertinggi didapatkan pada *sampling* I yaitu 91.39% dengan nilai  $\alpha = 0.1, 0.4, 0.7, 0.9$ .



Gambar 2. Hasil Akurasi Tertinggi LVQ 1 Pada Sampling I - IX

Pada Gambar 2 menunjukkan hasil akurasi terbaik dari ke-9 sampel yang diuji dengan metode LVQ 1. Pada *sampling* II, III, IV mendapatkan akurasi terbaik pada  $\alpha = 0.1$ . Pada *sampling* V akurasi terbaik dihasilkan pada  $\alpha = 0.4, 0.7, 0.9$ . Sedangkan pada *sampling* VI, VII, VIII, IX mencapai akurasi terbaik pada  $\alpha = 0.01$ .

### 3.2 LVQ 2



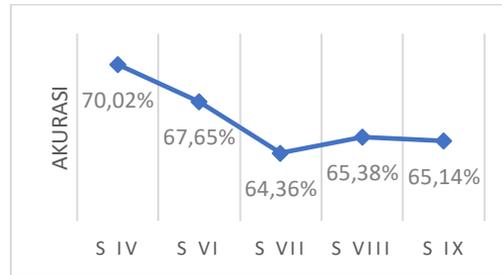
Gambar 3. Hasil Akurasi Tertinggi LVQ 2 Pada Sampling I - IX

Pada Gambar 3 menunjukkan hasil akurasi terbaik dari ke-9 sampel yang diuji dengan metode LVQ 2. Hasil akurasi tertinggi LVQ 2 terdapat pada *sampling* I dengan nilai  $\alpha = 0.9$  dan *window* 0.1. Pada *sampling* II hasil akurasi terbaik terdapat pada nilai  $\alpha = 0.00001$  dan *window* 0.1. *Sampling* III mendapatkan akurasi terbaik dengan nilai *window* yang sama pada *sampling* I dan II, tetapi dengan nilai  $\alpha$  berbeda yaitu 0.4. *Sampling* IV, V, VI, VII, VIII mendapatkan akurasi terbaik pada penggunaan seluruh nilai  $\alpha$  dan nilai *window* 0.0. Berbeda dengan *sampling* IX, akurasi terbaik hanya dicapai dengan nilai  $\alpha$  yang paling rendah yaitu 0.00001 tetapi dengan nilai *window* yang beragam yaitu 0.1, 0.2, 0.3, 0.4, dan 0.5.

### 3.3 LVQ 3

Pada LVQ 3 akurasi tertinggi dicapai pada *sampling* I dengan akurasi 80.04% pada  $\alpha = 0.7$ , *window* 0.1, dan epsilon 0.3. Pada *sampling* II akurasi terbaik mencapai 73.58%

dengan  $\alpha = 0.0001$ , *window* 0.2, 0.3, 0.4, 0.5, dan epsilon 0.5. Pada *sampling* III akurasi terbaik hanya mencapai 68.84% dengan  $\alpha = 0.9$ , *window* 0.2, dan epsilon 0.1. Sedangkan pada *sampling* V, akurasi terbaik hanya mencapai 65.57% dengan nilai  $\alpha$  terendah yaitu 0.00001, *window* 0.1, 0.2, 0.3, dan epsilon 0.1.



Gambar 4. Hasil Akurasi Tertinggi LVQ 3 Pada Sampling IV, VI, VII, VIII, IX

Pada Gambar 4 menunjukkan penggunaan metode LVQ 3 pada *sampling* IV, VI, VII, VIII, IX mendapatkan akurasi terbaik pada penggunaan seluruh nilai  $\alpha$ , nilai *window* 0, dan nilai epsilon 0.1, 0.2, 0.3, 0.5.

#### IV. KESIMPULAN

Penelitian ini menjelaskan bahwa penerapan multi-fitur dan teknik pengambilan data untuk pelatihan dan pengujian dapat berpengaruh terhadap keakuratan klasifikasi. Mekanisme pengambilan data terbaik terdapat pada metode LVQ 1 dengan menggunakan *sampling* I dengan jumlah data latih dan data uji 1231 dan 116. Rata-rata akurasi tertinggi mencapai 91.39% dengan *learning rate* ( $\alpha$ ) 0.1, 0.4, 0.7, 0.9, nilai *pengurang\_alfa* 0.01, *min\_alfa* 0.01. Pada LVQ 2, akurasi tertinggi hanya mencapai 77.05% pada *learning rate* ( $\alpha$ ) 0.9 dan *window* 0.2. LVQ 3 menghasilkan akurasi tertinggi 80.04 % pada *learning rate* ( $\alpha$ ) 0.7, *window* 0.1, epsilon 0.3. Penggunaan jumlah data dan parameter yang digunakan berpengaruh terhadap akurasi yang dihasilkan. Dengan demikian, implementasi metode LVQ 1, LVQ 2, dan LVQ 3 pada klasifikasi jenis kelamin berdasarkan pengukuran tengkorak mendapatkan akurasi terbaik pada metode LVQ 1. Untuk penelitian berikutnya dapat menggunakan metode ekstraksi fitur yang dikombinasikan dengan metode LVQ.

## DAFTAR PUSTAKA

- Abdillah, R., Sanjaya, S., & Afrianty, I. (2018). The Effect of Class Imbalance Against LVQ Classification. *International Conference on Electrical Engineering and Informatics (Icon EEI 2018)*, October, 42–45.
- Asadi, F., Chen, C.-A., Liu, T.-W., & Syafria, F. (2019). Acute Leukemia (ALL and AML) Classification Using Learning Vector Quantization (LVQ.1) With Blood Cell Imagery Extraction. *International Journal of Modeling and Optimization*, 9(3), 171–176. <https://doi.org/10.7763/ijmo.2019.v9.705>
- Bidmos, M. A., Adebessin, A. A., Mazengenya, P., Olateju, O. I., & Adegboye, O. (2021). Estimation of sex from metatarsals using discriminant function and logistic regression analyses. *Australian Journal of Forensic Sciences*, 53(5), 543–556. <https://doi.org/10.1080/00450618.2019.1711180>
- Budianita, B., Sanjaya, S., Syafria, F., & Redho. (2018). Penerapan Metode Learning Vector Quantization2 (LVQ 2) Untuk Menentukan Gangguan Kehamilan Trimester I. *Jurnal Sains, Teknologi Dan Industri*, 15(2), 144–151. <https://doi.org/10.24014/sitekin.v15i2.4861>
- Fukuta, M., Kato, C., Biwasaka, H., Usui, A., Horita, T., Kanno, S., Kato, H., & Aoki, Y. (2020). Sex estimation of the pelvis by deep learning of two-dimensional depth images generated from homologous models of three-dimensional computed tomography images. *Forensic Science International: Reports*, 2(July), 100129. <https://doi.org/10.1016/j.fsir.2020.100129>
- Kohonen, T. (1988). An introduction to neural computing. *Neural Networks*, 1(1), 3–16. [https://doi.org/10.1016/0893-6080\(88\)90020-2](https://doi.org/10.1016/0893-6080(88)90020-2)
- Kohonen, T. (1990a). Improved versions of learning vector quantization. *1990 IJCNN International Joint Conference on Neural Networks*, 1, 545–550. <https://doi.org/10.1109/IJCNN.1990.137622>
- Kohonen, T. (1990b). The Self-Organizing Map. *Proceedings of the IEEE*, 78(9), 1464–1480. <https://doi.org/10.1109/5.58325>
- Muzaqi, K., Junaidi, A., & Saputra, W. A. (2022). Klasifikasi Status Gizi Pada Lansia Menggunakan Learning Vector Quantization 3 (LVQ 3). *Journal of Dinda*, 2(1), 28–36.
- Toneva, D., Nikolova, S., Agre, G., Zlatareva, D., Hadjidekov, V., & Lazarov, N. (2021). Machine learning approaches for sex estimation using cranial measurements. *International Journal of Legal Medicine*, 135(3), 951–966. <https://doi.org/10.1007/s00414-020-02460-4>