

## Klasifikasi Penyakit Stroke Jaringan Syaraf Tiruan Menerapkan Metode Learning Vector Quantization

Puspa Melani Almahmuda Batubara<sup>1</sup>, Iis Afrianty<sup>2\*</sup>, Suwanto Sanjaya<sup>3</sup>, dan Fadhilah Syafria<sup>4</sup>

<sup>1,2,3,4</sup>Program Studi Teknik Informatika, Universitas Islam Negeri Sultan Syarif Kasim, Jalan HR. Soebrantas, Kota Pekanbaru, Riau 28293

e-mail: <sup>1</sup>11850124960@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>fadhilah.syafria@uin-suska.ac.id

Submitted Date: 2023-06-28

Revised Date: 2023-06-30

Reviewed Date: 2023-06-28

Accepted Date: 2023-06-30

### Abstract

*In Asia, where the majority of countries are developing, stroke is a serious problem, with the incidence and mortality of stroke often occurring in low- and middle-income countries. Minimising the number of stroke patients must be handled optimally, but the considerable economic burden in developing countries makes stroke patients urgently need to be given more attention and health care planning, especially in prevention efforts, as well as in early detection of stroke disease. Problem solving is done by classifying stroke disease using the Learning Vector Quantization (LVQ) method, which classifies stroke and non-stroke (normal) data based on disease symptoms. The dataset, obtained from Kaggle, consists of 4981 data points with 10 variables, including gender, age, marital status, hypertension, heart disease, occupation type, residence type, average glucose level, BMI (body mass index), and smoking status. The data is classified using LVQ by dividing it into 90:10, 80:20, 70:30, and 60:40 ratios, with learning rate parameters of 0.01 and 0.001, and 1000 epochs. From this classification process, the highest achieved is 70% is obtained by dividing the data 90%: 10%. Based on these results, the LVQ method in this study is capable of effectively classifying stroke diseases.*

*Keywords: Classification; Learning Vector Quantization; Stroke*


### Abstrak

Asia yang mayoritas negaranya berkembang menjadikan penyakit stroke masalah cukup serius, kejadian dan kematian akibat stroke sering terjadi di negara yang pendapatannya rendah dan menengah kebawah. Meminimalkan jumlah penderita stroke harus ditangani dengan optimal, namun beban ekonomi yang cukup besar di negara berkembang membuat penderita stroke sangat perlu untuk diberikan lebih banyak perhatian dan perencanaan perawatan kesehatan, terutama dalam upaya pencegahan, serta dalam mendeteksi dini penyakit stroke. Pemecahan masalah dengan melakukan klasifikasi penyakit stroke menggunakan metode *Learning Vector Quantization* (LVQ) dengan mengklasifikasikan data stroke dan tidak stroke (normal) berdasarkan gejala penyakit. Adapun dataset diperoleh dari situs Kaggle berjumlah 4981 data yang memiliki 10 variabel di antaranya jenis kelamin, usia, status pernikahan, hipertensi, penyakit jantung, tipe kerja, tipe tempat tinggal, *average glucose level* (kadar glukosa rata-rata), *Body Mass Index* (BMI), dan *smoking status*. Data tersebut dilakukan klasifikasi LVQ dengan membagi data yaitu 90:10, 80:20, 70:30 dan 60:40 dan parameter *learning rate* = 0,01 dan 0,001 serta *epoch* 1000. Dari proses klasifikasi LVQ tersebut maka didapatkan hasil akurasi tertinggi 70% diperoleh dengan membagi data 90% : 10%. Berdasarkan hasil tersebut, metode LVQ pada penelitian ini mampu melakukan klasifikasi penyakit stroke dengan cukup baik.

**Kata Kunci:** Klasifikasi; *Learning Vector Quantization*; Stroke

<http://openjournal.unpam.ac.id/index.php/informatika>

223



This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International (CC BY-NC 4.0) License

Copyright © 2023 Puspa Melani Almahmuda Batubara, Iis Afrianty, Suwanto Sanjaya, dan Fadhilah Syafria

## 1. Pendahuluan

Penyakit Stroke ialah salah satu penyakit penyebab kematian paling umum dan sering terjadi di dunia termasuk Asia sesudah penyakit jantung koroner dan kanker (Mutiarasari, 2019), angka kematian akibat stroke cukup tinggi, ada 10% kematian yang diakibatkan oleh stroke serta beban kecacatan permanen bagi penderitanya (Kamel et al., 2020). Asia yang mayoritas negaranya berkembang menjadikan penyakit stroke sebuah masalah yang cukup serius dibandingkan benua lain, ada 70% kejadian stroke dan 80% angka kematian akibat stroke. Negara-negara yang pendapatannya rendah dan menengah ke bawah memiliki tingkat kejadian stroke yang lebih tinggi (Turana et al., 2021). Meminimalkan meningkatnya jumlah penderita stroke harus dilakukan penanganan yang cepat dan tepat karena hal tersebut merupakan kondisi gawat darurat medis, namun beban ekonomi yang cukup besar di Negara berkembang membuat stroke sangat perlu untuk diberikan lebih banyak perhatian dan untuk perencanaan perawatan kesehatan yang lebih efektif, terutama dalam upaya pencegahan primer dan sekunder, serta dalam mendeteksi dini penyakit (Turana et al., 2021).

Analisis data dari GBD, 87% risiko stroke dapat diubah atau dimodifikasi faktor risiko HBP, obesitas, hiperglikemia, hyperlipidemia, dan disfungsi ginjal. 47% dikaitkan dengan faktor risiko perilaku seperti merokok, gaya hidup dan kebiasaan makan yang buruk, serta 30% risiko stroke disebabkan polusi udara (Tsao et al., 2022).

Kehadiran kecerdasan buatan dari salah satu cabang ilmu komputer dapat membantu pemecahan masalah dengan melakukan klasifikasi pada penyakit stroke, mendeteksi penyakit tersebut dapat dilakukan dengan melakukan klasifikasi atau pengelompokan penyakit stroke yang didasarkan gejala-gejala penyakit. Adapun penelitian terkait penyakit stroke dengan menganalisis kinerja algoritma mesin pembelajaran, adapun algoritma yang diterapkan yaitu, *logistic regression*, *naïve bayes*, *deep learning*, *neural network* untuk klasifikasi penyakit stroke dengan citra *CT Scan*. Dari beberapa algoritma tersebut, algoritma *deep learning* memiliki akurasi terbaik yaitu 96.79% (Sakinah et al., 2020). Penelitian lain dilakukan dengan menerapkan metode *backpropagation*

untuk mengidentifikasi penyakit stroke, hasil penerapan metode *backpropagation* menghasilkan tingkat akurasi data sebesar 97%, dengan tingkat error sebesar 3%. Hasil *Mean Square Error* (MSE) data pelatihan adalah 0.0009424 setelah melakukan 137 *epoch*. Perbandingan antara output dengan target menghasilkan MSE sebesar 0.0011488. (Antares, 2020).

Berdasarkan pemaparan pada penelitian terkait klasifikasi penyakit stroke, maka metode yang akan diusulkan pada penelitian klasifikasi penyakit stroke ini menggunakan metode *Learning Vector Quantization* (LVQ). *Learning Vector Quantization* (LVQ) merupakan salah satu algoritma yang digunakan dalam jaringan syaraf tiruan, merupakan sebuah metode pembelajarannya terawasi atau *supervised learning* dan jaringannya berupa *single layer* yang terdiri dari *competitive layer* (Adinugroho & Sari, 2017), yang di mana setiap lapisan melakukan pelatihan secara kompetitif dan lapisan ini belajar dengan otomatis untuk mengelompokkan vektor *input* yang diberikan, jika vektor *input* berada dalam jarak yang dekat, maka akan dikategorikan ke dalam satu kategori (Aziz et al., 2021).

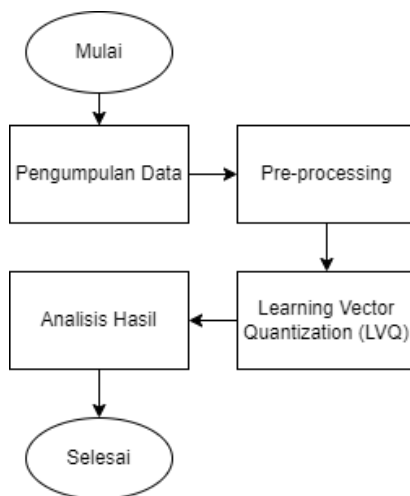
Adapun beberapa penelitian terkait metode LVQ dengan mengklasifikasi Penyakit Infeksi Saluran Pernafasan Akut (ISPA) dengan perbandingan data 80% : 20%, *learning rate* 0.2, 0.01 *error goal*, dan batasan maksimum iterasi sebesar 20, diperoleh tingkat akurasi yang tinggi yaitu rata-rata akurasi 96.5% dengan akurasi tertinggi 100% (Setyowati & Mariani, 2021). Penelitian lain melakukan klasifikasi risiko hipertensi dan mendapat nilai akurasi 93.841% dengan menggunakan *learning rate* 0.1, pengali *learning rate* 0.2, batasan minimum sebesar 0.001, dan iterasi maksimum sebanyak 6 (Agustinus et al., 2018). Penerapan metode *Learning Vector Quantization* (LVQ) untuk mendiagnosa penyakit Demam Berdarah Dengue (DBD). Dalam penelitian tersebut, ditemukan bahwa terdapat kombinasi parameter pelatihan yang menghasilkan nilai akurasi tertinggi sebesar 97,22% dengan nilai *Mean Square Error* (MSE) 0,02857. Salah satu kombinasinya adalah dengan menggunakan *learning rate* 0,1 dan 10 neuron pada lapisan tersembunyi (Tawakal & Azkiya, 2020).

Berdasarkan penjelasan yang telah dipaparkan, maka klasifikasi penyakit stroke akan menggunakan metode *Learning Vector*

*Quantization* (LVQ) dalam mengklasifikasi. Adapun parameter yang akan diterapkan dalam prosesnya adalah *learning rate* = 0.001, *epoch* = 1000.

## 2. Metode Penelitian

Metode penelitian ialah tahapan dari penelitian yang dilakukan secara sistematis. Adapun tahapan pada penelitian ini meliputi pengumpulan data, *pre-processing data*, menerapkan metode *Learning Vector Quantization* (LVQ), dan analisis hasil. Berikut tahapan penelitian pada gambar 1.



Gambar 1. Metode penelitian

Adapun penjelasan metode atau tahapan penelitian adalah sebagai berikut:


### A. Pengumpulan data

Data mengenai stroke yang dipergunakan dalam penelitian ini ialah data sekunder, yang diambil dari situs Kaggle. Data stroke yang diperoleh memiliki total 4981 data, berikut tampilan data pada gambar 2.

gender	age	hypertension	heart_disease	ever_married	work_type	Residence_type	avg_glucose_level	bmi	smoking_status
Male	67.0	0	1	Yes	Private	Urban	228.69	36.6	formerly smoked
Male	80.0	0	1	Yes	Private	Rural	105.92	32.5	never smoked
Female	49.0	0	0	Yes	Private	Urban	171.23	34.4	smokes
Female	79.0	1	0	Yes	Self-employed	Rural	174.12	24.0	never smoked
Male	81.0	0	0	Yes	Private	Urban	186.21	29.0	formerly smoked
--	--	--	--	--	--	--	--	--	--
Male	41.0	0	0	No	Private	Rural	70.15	29.8	formerly smoked
Male	40.0	0	0	Yes	Private	Urban	191.15	31.1	smokes
Female	45.0	1	0	Yes	Govt_Job	Rural	95.02	31.8	smokes
Male	40.0	0	0	Yes	Private	Rural	83.94	30.0	smokes
Female	80.0	1	0	Yes	Private	Urban	83.75	29.1	never smoked

Gambar 2. Data penyakit stroke

Dilihat dari Gambar 2 bahwa data tersebut memiliki 10 variabel di antaranya jenis kelamin, usia, status pernikahan, hipertensi, penyakit jantung, tipe kerja, tipe tempat tinggal, *average glucose level* (kadar glukosa rata-rata), *Body Mass Index* (BMI), dan *smoking status*. Serta output terbagi dua kelas yaitu data tidak stroke (normal) dan stroke dengan perbandingan 4733 : 248 data, berikut tampilan kelas data tidak stroke dan stroke pada gambar 3.



Gambar 3. Tampilan kelas tidak stroke dan stroke

Gambar di atas menampilkan tampilan kelas data stroke dan tidak stroke. Dilihat pada gambar 3 diketahui bahwa data stroke dan tidak stroke tidak seimbang, sehingga data yang tidak seimbang tersebut mesti dilakukan *preprocessing data* sebelum dilakukan pembelajaran LVQ.

### B. Pre-processing Data (Olah Data)

Setelah data terkumpul, dilakukan olah data atau *pre-processing data* agar data yang digunakan optimal sehingga mendapatkan hasil yang lebih tepat (Chandra & Juan, 2022). Pada tahap ini data dilakukan transformasi data, mengubah data *categorical* menjadi *numeric*. Adapun tampilan data yang sudah dilakukan transformasi bisa dilihat pada gambar 4.

gender	age	hypertension	heart_disease	ever_married	work_type	Residence_type	avg_glucose_level	bmi	smoking_status
0	67.0	0	1	1	1	1	228.69	36.6	1
0	80.0	0	1	1	1	0	105.92	32.5	2
1	49.0	0	0	1	1	1	171.23	34.4	3
1	79.0	1	0	1	2	0	174.12	24.0	2
0	81.0	0	0	1	1	1	186.21	29.0	1
--	--	--	--	--	--	--	--	--	--
0	41.0	0	0	0	1	0	70.15	29.8	1
0	40.0	0	0	1	1	1	191.15	31.1	3
1	45.0	1	0	1	0	0	95.02	31.8	3
0	40.0	0	0	1	1	0	83.94	30.0	3
1	80.0	1	0	1	1	1	83.75	29.1	2

Gambar 4. Transformasi Data

Setelah transformasi, data tersebut dilakukan *balance data* karena jumlah data yang tidak seimbang yang di mana perbandingan data penderita stroke dan tidak stroke (normal) adalah 248 : 4733 dapat dilihat pada gambar 3. Jika data tidak seimbang digunakan maka kelas minoritas (data stroke) akan memiliki akurasi yang cukup rendah dibandingkan kelas mayoritas (data tidak stroke), oleh sebab itu agar meminimalkan terjadinya kesalahan pada proses pembelajaran dilakukan *balance data* (Maxwell et al., 2018). Setelah data diseimbangkan kemudian dilakukan normalisasi data, berikut rumus normalisasi yang akan digunakan.

$$V' = \frac{v - \min_A}{\max_A - \min_A} (\text{new}_{\max_A} - \text{new}_{\min_A}) + \text{new}_{\min_A} \quad (1)$$

Normalisasi dilakukan karena variabel dalam dataset memiliki skala yang berbeda jauh, normalisasi data membantu menghindari masalah ini dengan menormalkan skala variabel dengan mengubah nilai-nilai variabel menjadi rentang tertentu, biasanya berkisar antara 0 sampai 1.

### C. Learning Vector Quantization (LVQ)

*Learning Vector Quantization* (LVQ) adalah sebuah algoritma jaringan syaraf tiruan yang metode pembelajarannya terawasi dan jaringannya berupa *single layer* yang terdiri dari *competitive layer* (Adinugroho & Sari, 2017). Berikut tahapan singkat metode LVQ:

- 1) Menetapkan parameter yang akan digunakan
- 2) Menetapkan kondisi awal atau inisialisasi awal
- 3) Memproses jika ( $epoch < \max.epoch$ ) atau ( $\alpha > eps$ )
- 4) Pelatihan input data (*training data*) mengikuti langkah – langkah selanjutnya
- 5) Menghitung jarak *vector* menggunakan rumus.

$$D(j) = \sum (w_{ij} - x_i)^2 \quad (2)$$

cari  $j$  ketika  $C(j)$  minimum.

- 6) Memperbarui  $w_j$  atau bobot pemenang dimana:

Jika  $T = C(j)$ , maka;

$$w_j(\text{baru}) = w_j(\text{lama}) + \alpha (x_i - w_j(\text{lama})) \quad (3)$$


Jika  $T \neq C(j)$ , maka;

$$w_j(\text{baru}) = w_j(\text{lama}) - \alpha (x_i - w_j(\text{lama})) \quad (4)$$

- 7) kembali ke langkah 5 hingga semua *vector* memiliki kelas
- 8) Mengurangi nilai *learning rate* ( $\alpha$ )
- 9) Proses berhenti jika sudah mencapai *max.epoch* atau sudah mencapai nilai toleransi kesalahan (error).

### 3. Hasil dan Pembahasan

Data yang digunakan berjumlah 4981 data, yang memiliki 10 variabel yaitu jenis kelamin, usia, status pernikahan, hipertensi, penyakit jantung, tipe kerja, tipe tempat tinggal, *average glucose level* (kadar glukosa rata-rata), *Body Mass Index* (BMI), dan *smoking status*, serta output terbagi dua kelas yaitu data stroke dan tidak stroke (normal). Data tersebut dilakukan transformasi dapat dilihat pada gambar 3, kemudian dilakukan *balance data* karena dalam prosesnya ditemukan data yang timpang yaitu 4733 data tidak stroke (mayoritas) dan 248 data stroke (minoritas). Setelah itu dilakukan normalisasi menggunakan persamaan (1). Selanjutnya dilakukan implementasi metode LVQ, adapun proses tahapan dari metode LVQ dapat ditunjukkan oleh gambar 5.



Gambar 5. Flowchart LVQ

Langkah awal adalah melakukan inialisasi bobot secara acak pada model LVQ kemudian melatih model LVQ dengan menggunakan parameter yaitu  $epoch = 1000$ ,  $learning\ rate = 0.01$  dan  $0.001$  serta pengurangan  $learning\ rate = 1$ . Adapun skenario pengujian yang akan dilakukan dengan pengujian  $learning\ rate$  pada rasio data yang berbeda. Berikut beberapa skenario pengujian yang dilakukan dapat dilihat pada tabel 1.

Tabel 1. Skenario pengujian

Skenario	Rasio Data	Learning Rate ( $\alpha$ )	
Skenario 1	90% : 10%	0,01	0,001
Skenario 2	80% : 20%	0,01	0,001
Skenario 3	70% : 30%	0,01	0,001
Skenario 4	60% : 40%	0,01	0,001

Pada skenario 1, dilakukan implementasi LVQ menggunakan perbandingan data 90%:10% yang di mana jumlah data pelatihan sebanyak 8519 data dan jumlah data pengujian sebanyak 947 data. Dari hasil pengujian tersebut mendapatkan akurasi 70%, presisi 0,72,  $recall$  0,70 dan  $f1\ score$  0,69 dengan menggunakan  $learning\ rate$  0,001. sedangkan dengan  $learning\ rate$  0,01 mendapat akurasi 70% presisi 0,70  $recall$  0,70 dan  $f1\ score$  0,70.

Untuk skenario 2 implementasi LVQ dilakukan dengan menggunakan perbandingan data 80%:20% yang di mana jumlah data pelatihan sebanyak 7572 data dan jumlah data pengujian sebanyak 1894 data yang mendapat akurasi 68%, presisi 0,68  $recall$  0,68 dan  $f1\ score$  0,68 dengan menggunakan  $learning\ rate$  0,001. Sedangkan dengan  $learning\ rate$  0,01 mendapat akurasi 69% presisi 0,69  $recall$  0,69 dan  $f1\ score$  0,69.

Pada skenario 3 dilakukan implementasi LVQ menggunakan perbandingan data 70%:30% yang di mana jumlah data pelatihan 6626 data dan jumlah data pengujian 2840 data. Dari pengujian didapatkan akurasi 69%, presisi 0,71,  $recall$  0,69, dan  $f1\ score$  0,68 dengan menggunakan  $learning\ rate$  0,001. Sedangkan dengan  $learning\ rate$  0,01 mendapat akurasi 68% presisi 0,69  $recall$  0,68 dan  $f1\ score$  0,68.

Skenario 4 dilakukan implementasi LVQ menggunakan perbandingan data 60%:40% yang di mana jumlah data pelatihan 5679 data dan jumlah data pengujian 3787 data yang mendapat akurasi sebesar 65%, presisi 0,65  $recall$  0,65 dan  $f1\ score$  0,64 dengan menggunakan  $learning\ rate$  0,001. Sedangkan dengan  $learning\ rate$  0,01

mendapat akurasi 68% presisi 0,69  $recall$  0,68 dan  $f1\ score$  0,68.

Setelah dilakukan beberapa skenario pengujian menggunakan metode LVQ, maka hasil pengujian tersebut ditampilkan ke dalam tabel. Tabel dibawah ini memberikan gambaran perbandingan dari setiap skenario yang diuji, berikut hasil pengujian yang tertera pada tabel 2.

Tabel 2. Hasil Pengujian

Pembagian Data	Akurasi dengan $\alpha = 0,01$	Akurasi dengan $\alpha = 0,001$
90%:10%	70%	70%
80%:20%	69%	68%
70%:30%	68%	69%
60%:40%	68%	65%

Berdasarkan penjelasan yang telah dipaparkan, maka proses pengujian klasifikasi penyakit stroke pada penelitian ini dapat dikatakan bahwa pada pengujian:

- 1) Semakin sedikit data pelatihan pada pengujian maka akurasi yang dihasilkan semakin rendah dibandingkan dengan data pelatihan yang lebih banyak.
- 2) Tingkat akurasi terendah terjadi pada pembagian data 60%:40% yang hasil akurasinya adalah 65% dengan  $learning\ rate$  0,001.
- 3) Perbandingan data 90%:10% pada tabel 2 didapati akurasi yang sama, namun pada  $learning\ rate$  0,001 di ketahui bahwa nilai presisi,  $recall$ , dan  $f1\ score$  lebih tinggi dibandingkan dengan  $learning\ rate$  0,01.
- 4) Tingkat akurasi tertinggi terjadi pembagian data 90%:10% yang hasil akurasinya 70% dengan  $learning\ rate$  0,001.
- 5) Performa model pada pengujian  $learning\ rate$  0,001 dengan perbandingan data 90%:10% dapat dianggap baik, karena memiliki presisi dan  $recall$  yang relatif tinggi, serta nilai  $f1\ score$  yang cukup seimbang.

#### 4. Kesimpulan

Berdasarkan hasil pengujian menggunakan metode *Learning Vector Quantization* (LVQ), dengan melakukan parameter uji  $learning\ rate = 0.001$ ,  $epoch = 1000$  dan pembagian data 90%:10%, maka didapat akurasi tertinggi 70%,

presisi 0,72 *recall* 0,70 dan *f1 score* 0,69. Jadi dapat disimpulkan bahwa pada penelitian ini metode LVQ mampu mengenali klasifikasi penyakit stroke.

## 5. Saran

Sebagai rekomendasi untuk penelitian selanjutnya, disarankan untuk menggunakan parameter uji lain dengan mencari parameter terbaiknya sehingga mendapat akurasi yang lebih baik, serta mempertimbangkan penggunaan metode pembelajaran *Learning Vector Quantization* (LVQ) yang lain yaitu, LVQ 2 dan LVQ 3 yang mungkin proses pembelajarannya lebih baik dibandingkan proses LVQ pada penelitian ini.

## Referensi

- Adinugroho, S., & Sari, Y. A. (2017). Perbandingan Jaringan Learning Vector Quantization dan Backpropagation pada Klasifikasi Daun Berbasis Fitur Gabungan. *Jurnal Informatika & Multimedia*, 9(02), 58–64.
- Agustinus, I., Santoso, E., & Rahayudi, B. (2018). Klasifikasi Risiko Hipertensi Menggunakan Metode Learning Vector Quantization (LVQ). *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*.
- Antares, J. (2020). Artificial Neural Network Dalam Mengidentifikasi Penyakit Stroke Menggunakan Metode Backpropagation (Studi Kasus di Klinik Apotik Madya Padang). *Djtechno: Jurnal Teknologi Informasi*, 1(1), 6–13.
- Aziz, A. R., Warsito, B., & Prahutama, A. (2021). Pengaruh Transformasi Data Pada Metode Learning Vector Quantization Terhadap Akurasi Klasifikasi Diagnosis Penyakit Jantung. *Jurnal Gaussian*, 10(1), 21–30.
- Chandra, R., & Juan, D. C. (2022). Deteksi Pesan Spam pada Forum Daring Menggunakan Metode Naïve Bayes. *Jurnal Informatika Universitas Pamulang*, 7(2), 369–373.
- Kamel, H., Navi, B. B., Parikh, N. S., Merkle, A. E., Okin, P. M., Devereux, R. B., Weinsaft, J. W., Kim, J., Cheung, J. W., Kim, L. K., Casadei, B., Iadecola, C., Sabuncu, M. R., Gupta, A., & Díaz, I. (2020). Machine Learning Prediction of Stroke Mechanism in Embolic Strokes of Undetermined Source. *Stroke*, 51(9), 203–210. <https://doi.org/10.1161/STROKEAHA.120.029305>
- Maxwell, A. E., Warner, T. A., & Fang, F. (2018). Implementation of Machine-Learning Classification in Remote Sensing: An Applied Review. *International Journal of Remote Sensing*, 39(9), 2784–2817.
- Mutiarasari, D. (2019). Ischemic Stroke: Symptoms, Risk Factors, and Prevention. *Medika Tadulako, Jurnal Ilmiah Kedokteran*, 6(1), 60–73.
- Sakinah, N., Badriyah, T., & Syarif, I. (2020). Analisis Kinerja Algoritma Mesin Pembelajaran untuk Klarifikasi Penyakit Stroke Menggunakan Citra CT Scan. *Jurnal Teknologi Informasi Dan Ilmu Komputer (JTIK)*, 7(4), 833–844.
- Setyowati, E., & Mariani, S. (2021). Penerapan Jaringan Syaraf Tiruan dengan Metode Learning Vector Quantization (LVQ) untuk Klasifikasi Penyakit Infeksi Saluran Pernapasan Akut (ISPA). *PRISMA, Prosiding Seminar Nasional Matematika*, 4, 514–523.
- Tawakal, F., & Azkiya, A. (2020). Diagnosa Penyakit Demam Berdarah Dengue (DBD) menggunakan Metode Learning Vector Quantization (LVQ). *JISKA (Jurnal Informatika Sunan Kalijaga)*, 4(3), 193–201.
- Tsao, C. W., Aday, A. W., Almarzooq, Z. I., Alonso, A., Beaton, A. Z., Bittencourt, M. S., Boehme, A. K., Buxton, A. E., Carson, A. P., Commodore-Mensah, Y., Elkind, M. S. V., Evenson, K. R., Eze-Nliam, C., Ferguson, J. F., Generoso, G., Ho, J. E., Kalani, R., Khan, S. S., Kissela, B. M., ... Martin, S. S. (2022). Heart Disease and Stroke Statistics-2022 Update: A Report from the American Heart Association. In *Circulation*
- Turana, Y., Tengkawan, J., Chia, Y. C., Nathaniel, M., Wang, J. G., Sukonthasarn, A., Chen, C. H., Minh, H. Van, Buranakitjaroen, P., Shin, J., Siddique, S., Niales, J. M., Park, S., Teo, B. W., Sison, J., Ann Soenarta, A., Hoshide, S., Tay, J. C., Prasad Sogunuru, G., ... Kario, K. (2021). Hypertension and stroke in Asia: A comprehensive review from HOPE Asia. *Journal of Clinical Hypertension*, 23(3).