



Identifikasi *Diabetes Mellitus* Menggunakan Sensor Gas QCM Dengan Metode *Learning Vector Quantization*

Ade Ruldy Prasetya*¹, Misbah²

^{1,2}Universitas Muhammadiyah Gresik; Jl. Sumatera No. 101 GKB, 031 395 1414
Jurusan Teknik Elektro, Universitas Muhammadiyah, Gresik

*Email Penulis Korespondensi: aderuldyp@gmail.com

Abstrak

Informasi tentang diabetes sering kali diabaikan, sehingga menyebabkan diagnosa yang salah dan berakhir buruk. Identifikasi diabetes mellitus menggunakan gas sensor dengan metode *Learning Vector Quantization (LVQ)* merupakan salah satu upaya untuk memberikan informasi seseorang terjangkit diabetes atau tidak, dikarenakan kurangnya pengetahuan terhadap gejala diabetes mellitus. Sebagian besar deteksi saat ini masih berbasis dalam menganalisis darah yang dilakukan secara invasif, Hal ini membuat ketidaknyamanan bagi pasien penderita jika dilakukan pemeriksaan secara berulang. Dalam upaya mengatasi masalah tersebut, penelitian ini bertujuan untuk mengidentifikasi diabetes mellitus melalui pendekatan non invasif menggunakan sensor gas Quartz Crystal Microbalance (QCM) yang dilapisi dengan lapisan carbon nanotubes termasuk single walled, multi walled dan graphene oxide sebagai indikator. Metode LVQ diterapkan untuk mengklasifikasi pasien berdasarkan parameter kondisi urin. Hasil penelitian menunjukkan bahwa metode LVQ mencapai akurasi tertinggi sebesar 83.33% dengan percobaan pembelajaran yang tepat, yaitu pembelajaran α sebesar 0.1, $\text{dec } \alpha$ sebesar 0.0001 dan epoch sebesar 1000, pada pembagian data 90% untuk data latih dan 10% untuk data uji. Penelitian ini menunjukkan potensi pendekatan sebagai alternatif non invasif yang efektif dalam deteksi diabetes mellitus.

Kata kunci— *Diabetes mellitus, Learning vector quantization, Carbon nanotubes, Sensor gas*

Abstract

Information about diabetes is often overlooked, leading to misdiagnosis and adverse outcomes. Using gas sensors with *Learning Vector Quantization (LVQ)* method to identify diabetes mellitus is an effort to provide insight into whether someone has the condition or not, given the lack of knowledge about its symptoms. Currently, most detections rely on invasive blood analysis, causing discomfort for patients undergoing repeated examinations. To address this issue, this research aims to identify diabetes mellitus through a non-invasive approach using Quartz Crystal Microbalance (QCM) gas sensors coated with carbon nanotubes, including single-walled, multi-walled, and graphene oxide as indicators. The LVQ method is applied to classify patients based on urine condition parameters. The research findings indicate that the LVQ method achieved the highest accuracy of 83.33% with appropriate learning experiments, including a α of 0.1, $\text{dec } \alpha$ of 0.0001, and an epoch of 1000, with a data split of 90% for training

and 10% for testing. This study demonstrates the potential of the approach as an effective non-invasive alternative in detecting diabetes mellitus.

Keywords—*Diabetes mellitus, Learning vector quantization, Carbon nanotubes, Sensor gas*

1. PENDAHULUAN

Diabetes Mellitus (DM) adalah gangguan *metabolism* makromolekul yang ditandai dengan ketidakmampuan tubuh untuk menghasilkan atau merespon hormon dan mempertahankan kadar gula darah yang tepat. Penyakit ini mungkin merupakan penyakit jangka Panjang yang menyebabkan saluran kelenjar tidak lagi mampu menghasilkan endokrin atau Ketika tubuh tidak dapat mengawasi bagaimana endokrin yang dihasilkan digunakan. Gejala rasa haus yang meningkat, dan sering buang air kecil disebabkan oleh peningkatan gula darah ini sehingga menyebabkan banyak konsekuensi jika tidak ditangani [1]. Analisis cairan antar sel, darah vena, dan darah jari adalah pemeriksaan invasif yang paling umum digunakan dalam diagnosis glukosa darah [2]. Faktor genetik, lingkungan, dan perilaku, termasuk pola makan yang buruk dan gaya hidup yang tidak banyak bergerak, seringkali berkontribusi pada obesitas dan diabetes. Pola makan yang terlalu banyak makanan olahan, gula, dan lemak jenuh dikombinasikan dengan kurangnya aktivitas fisik meningkatkan risiko obesitas dan diabetes [3].

Sebuah algoritma yang disebut *neural network* terinspirasi oleh jaringan saraf biologi manusia yang saling berhubungan, ditiru, dan akhirnya diubah menjadi model pembelajaran yang dapat dibaca oleh komputer. Metode terkenal di NN mencakup berbagai topik, *Learning vector quantization* adalah salah satunya [4]. Karena kompleksitasnya yang berkurang, kurva pembelajarannya, dan bentuk buku kodenya, LVQ terkadang dianggap sebagai klasifikasi arsitektur yang universal, efisien, dan mudah [5].

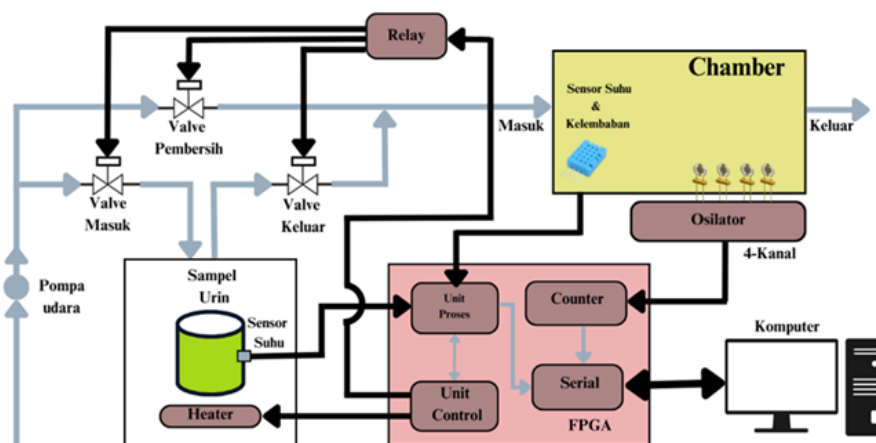
Dengan menggunakan metode ini, hasil akurasi yang diperoleh dari beberapa studi serupa sebelumnya adalah 67% jumlah rate tertinggi untuk klasifikasi *Learning rate* adalah 0,01 dan nilai tertinggi untuk Epoch adalah 50 dari skala 10-50 [6], pada metode yang sama juga dilakukan pengujian mendapatkan hasil tingkat akurasi terbaik pada tahap 1 adalah 96,67% dengan laju pelatihan 0,7 dan laju penurunan 0,75. Tingkat akurasi terbaik pada tahap 2 adalah 92,5% dengan berbagai variasi laju pelatihan dan laju penurunan [7]. Pada kasus yang sama akurasi tertinggi didapat dalam proses pembelajaran model klasifikasi LVQ pada formasi simulasi adalah 96% pada proses pengujian dan 90% pada proses pelatihan. dengan parameter adalah $\alpha = 0,1$ dan $dec \alpha = 0,01$, masing-masing [8]. Tingkat akurasi puncak mencapai 100% dengan membagi data latih 90% dan data uji 10%, pada penelitian serupa. Hal ini berhasil dicapai dengan memanfaatkan learning rate (α) sebesar 0,0001, dengan minimum learning rate (α) setidaknya 0,00001, serta menggunakan koefisien pelebaran (β_1) sebesar 1,3 dan koefisien penyempitan (β_2) sebesar 0,6 [9]. Menghasilkan nilai 0.1 untuk α , 0.4 untuk $dec \alpha$, serta perbandingan jumlah data latih dan data uji sebesar 100 banding 35. Maksimal epoch diatur sebesar 10, dan nilai $min \alpha$ ditetapkan pada 0,001. Dengan konfigurasi tersebut, akurasi rata-rata akhir mencapai 81,13% [10].

Sensor gas yang digunakan adalah sensor *quartz crystal microbalance* (QCM) yang dilapisi dengan *carbon nanotube* untuk pengambilan sample data dari gas urin yang. QCM merupakan resonator elektromekanis piezoelektrik yang berinteraksi dengan lingkungannya dan mengubah perilaku resonansinya sebagai hasil dari berbagai mekanisme interaksi. Meskipun memiliki beberapa bidang aplikasi yang terkonsolidasi, QCM masih menjadi subyek dari banyak penelitian yang ditujukan untuk meningkatkan kinerja dari berbagai perspektif [11]. *Carbon nanotube* telah dipelajari dan dikembangkan untuk mendeteksi aseton dan berbagai senyawa lainnya dalam sampel gas. Mereka sangat peka terhadap senyawa-senyawa yang sangat kecil. Oleh karena itu, mereka dapat digunakan sebagai perangkat medis untuk memantau kondisi seperti diabetes, yang mana deteksi dini dapat sangat penting untuk mengelola kondisi dengan lebih baik [12, 13]. Untuk penelitian ini, metode LVQ dan sensor QCM dipilih berdasarkan

berbagai faktor. Ini termasuk keunggulan teknis, praktis, dan ketersediaan sumber daya. Sementara LVQ terbukti berguna untuk klasifikasi data, sensor QCM sangat sensitif dan responsif terhadap perubahan massa gas, menjadikannya pilihan yang baik untuk pengambilan sampel gas seperti gas urin dalam penelitian medis. Sensor QCM mudah digunakan dan memungkinkan pengambilan sampel gas secara non-invasif. Studi sebelumnya juga telah menunjukkan bahwa metode ini efektif, dan keduanya mudah digunakan dan murah. Dengan mempertimbangkan hal-hal ini, penggunaan LVQ dan sensor QCM dianggap sebagai metode yang paling efektif untuk mencapai tujuan penelitian.

2. METODE PENELITIAN

Rekam medis pasien *diabetes mellitus* di sebuah rumah sakit pada tahun 2022 menjadi sumber data penelitian. Berdasarkan data yang ada, akan dikembangkan model klasifikasi penderita diabetes dari data yang tersedia. Namun, hanya dua kelas yang akan digunakan sebagai output yaitu sehat dan terjangkit karena ketersediaan data yang terbatas. Terdapat 114 bekas rekam medik, diantaranya pasien sakit diabetes mellitus 51 data dan 63 data pasien sehat atau bebas diabetes mellitus. Dalam penelitian ini, perancangan sistem terdiri dari pompa udara, sampel urin, tiga *valve*, chamber yang berisi empat sensor QCM, pemanas, rangkaian osilator, FPGA, dan komputer. Gambar 1 blok diagram sistem dimana pada saat pengambilan data tersebut.



Gambar 1. Blok diagram sistem

2.1 Carbon nanotubes

CNT adalah struktur nano yang terdiri dari atom *carbon* yang tersusun dalam bentuk tabung berongga. Mereka memiliki diameter sekitar satu nanometer hingga beberapa puluh nanometer dan panjangnya dapat mencapai beberapa mikrometer hingga beberapa sentimeter. CNT memiliki sifat-sifat yang unik, termasuk kekuatan yang sangat tinggi, keuletan, konduktivitas termal dan listrik yang luar biasa, serta kemampuan untuk berperilaku sebagai konduktor atau semikonduktor tergantung pada strukturnya. Karena sifat-sifat ini, CNTs memiliki berbagai aplikasi potensial dalam berbagai bidang, seperti elektronika, bahan komposit, sensor, bidang kesehatan, dan banyak lagi.

CNT pada dasarnya adalah lembaran grafit yang digulung menjadi tabung. Atom *carbon* dalam lembaran grafit ini tersusun secara heksagonal dalam sp^2 . Satu atau lebih lapisan rantai carbon heksagonal membentuk struktur ini. Panjang tabung berada pada skala mikro, dan diameternya kira-kira 1 nm. *carbon nanotube* ber dinding multi (MWCNT) memiliki kekuatan tarik 11-63 IPK dan modulus *Young* 270-950 IPK. *carbon nanotube* ber dinding tunggal (SWCNT) memiliki kekuatan tarik 50-100 GPa dan modulus *Young* 1-2 TPa. Penelitian ini

menggunakan tiga CNT dan bahan graphene oksida (GO) beserta bahannya jenis dan ukuran, seperti pada Tabel 1 [14].

Tabel 1 Tipe clearcarbon material

Nano material	Diameters (nm)	Panjang (μm)	Kemurnian (%)
<i>Single walled carbon nanotube</i> (SWCNT)	1 - 2	5 - 30	95
<i>Multi walled carbon nanotube</i> (MWCNT)	4 - 6	0.5 - 2	98
<i>Multi walled carbon nanotube</i> (MWCNT)	10 - 30	0.5 - 2	98
Graphene oxide (GO)	-	8 - 15	98


2.2 Quartz crystal microbalance

Resonator elektromekanis piezoelektrik yang berinteraksi dengan lingkungannya dan mengubah perilaku resonansinya sebagai hasil dari berbagai mekanisme interaksi. Penginderaan gas, penginderaan kelembaban, penginderaan partikel, biosensor untuk berbagai target biologis, pemantauan pertumbuhan film dalam endapan elektrokimia, dan pengukuran viskositas cairan hanyalah beberapa aplikasi untuk sistem penginderaan berbasis *Quartz Crystal Microbalance* (QCM). Meskipun memiliki beberapa bidang aplikasi yang terkonsolidasi, *Quartz Crystal Microbalance* (QCM) masih menjadi subyek dari banyak penelitian yang ditujukan untuk meningkatkan kinerja dari berbagai perspektif.

Sensor QCM sangat sensitif terhadap molekul gas yang menempel pada elektroda. Sensor ini akan mengubah frekuensi osilasi resonator kuarsa (Δf), yang didefinisikan sebagai:

$$\Delta f = - \left(\frac{2f^2}{\sqrt{\rho\mu}} \right) \Delta m \quad (1)$$


Dimana Δf adalah pergeseran frekuensi yang diamati (Hz), Δm adalah perubahan massa per satuan luas (g/cm^2), ρ adalah kerapatan kristal, v adalah kecepatan rambat gelombang akustik pada kristal kuarsa, A adalah luas permukaan (cm^2).



Gambar 2. Prinsip dasar sensor QCM [15].

2.3 Learning vector quantization

Metode Klasifikasi yang dikenal dengan *Learning Vector Quantization* (LVQ) menggunakan pola untuk setiap unit yang ada untuk mengklasifikasikannya ke dalam salah satu dari sejumlah kelas yang telah ditentukan [8]. Pengurangan node terdekat, atau tetangga, adalah prinsip dasar algoritma LVQ yang ditunjukkan oleh arsitektur LVQ pada Gambar 3 [16, 17]. Berdasarkan variable yang ada pada klasifikasi ini yaitu $X_1 = \text{SW}$, $X_2 = \text{M0406}$, $X_3 = \text{M1030}$, dan $X_4 = \text{GO}$

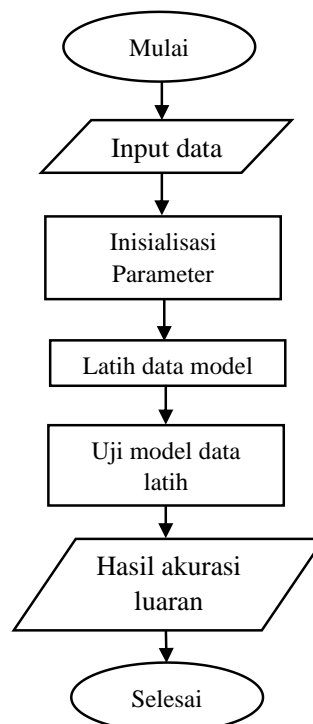


Gambar 3 Arsitektur LVQ

Keterangan :

- X1 – X4 nilai *input*
- $\|X - w1\| - \|X - w2\|$ Jarak Bobot
- F1 – F2 nilai *output*

Diagram flowchart untuk model klasifikasi tahap pengembangan LVQ untuk diagnosis diabetes ditunjukkan pada Gambar 4.



Gambar 4 Flowchart klasifikasi diagnosis diabetes.

Proses algoritma LVQ pada data latih adalah :

1. Tahap awal adalah menginisialisasi nilai *learning rate* (α), pengurangan *learning rate* (*Dec* α), maksimal epoch yang digunakan dan *minimal rate* (*min* α) yang akan digunakan serta menentukan bobot awal setiap kelas atau target

2. Masukkan data input serta kelas atau kategori target
3. Kerjakan apabila ($epoch \leq max\ epoch$ dan $\alpha \geq min\ \alpha$):
 - a. Epoch = epoch + 1;
 - b. Melakukan perhitungan jarak minimum dengan menggunakan *Euclidean distance*.

$$D_i = \sqrt{\sum_{j=1}^n (x_j - w_{ij})^2} \quad (2)$$

- c. Melakukan update bobot untuk memperbaiki nilai bobot dengan kondisi:

- Jika $T = C_j$ maka;

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

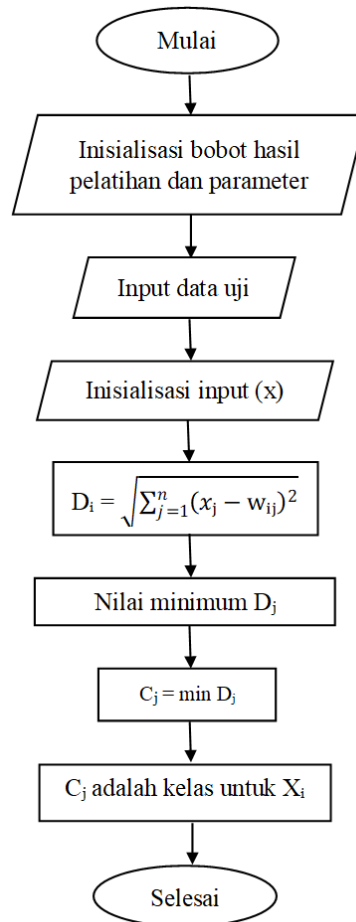
- Jika $T \neq C_j$ maka;

$$W_j (\text{baru}) = W_j (\text{lama}) - \alpha (X_i - W_j (\text{lama})) \quad (4)$$

- d. Melakukan pengurangan pada nilai α dengan cara:

$$\alpha (\text{baru}) = \alpha (\text{lama}) - (\alpha * dec\ \alpha) \quad (5)$$

4. Proses akan berhenti jika telah mencapai maksimum epoch atau nilai *learning rate* (α) telah minimum.
5. Setelah proses pelatihan selesai, maka akan diperoleh bobot-bobot akhir (w) [10].



Gambar 5 Flowchart uji model LVQ

Setelah model klasifikasi dibangun menggunakan data pelatihan, pengujian dilakukan untuk menguji dan mengukur keakuratan data yang dihasilkan model klasifikasi. Sistem klasifikasi diharapkan dapat mengklasifikasikan semua kumpulan data dengan benar, tetapi tidak ada keraguan bahwa kinerjanya tidak bisa 100% tepat.

3. HASIL DAN PEMBAHASAN

Parameter yang berbeda digunakan dalam pelatihan jaringan untuk membuat model klasifikasi untuk mendiagnosis pasien diabetes mellitus. parameter ini ditentukan pada Tabel 2.

Tabel 2 Parameter pelatihan LVQ

Parameter	Nilai
Jumlah data	114
Variasi pembagian data	70%:30%, 80%:20%, 90%:10%
Kelas	2
Variasi pelatihan α	0.1-0.9
Tingkat $dec \alpha$	0.001, 0.01, 0.1
Max epoch	1000

Pengujian *Learning Rate*: Bertujuan mengidentifikasi dampak perubahan *learning rate* terhadap hasil akurasi. Nilai *learning rate* yang akan diuji adalah 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, dan 0.9. Jika nilai terlalu kecil digunakan, maka hasilnya tidak signifikan sehingga tidak dapat diamati perubahannya, dan jika nilai terlalu besar digunakan, maka hasilnya semakin tidak akurat dan tidak stabil selama proses pengajaran.

Pengujian Pengaruh Epoch: Tujuan dari pengujian adalah untuk mengetahui bagaimana epoch berdampak pada akurasi hasil.

Pengujian pengaruh $dec \alpha$: Tujuannya adalah untuk mengetahui seberapa akurat, presisi, dan *recall* model LVQ terhadap dataset yang digunakan. Ini membantu dalam menentukan seberapa efektif model tersebut dalam mempelajari pola data yang ada dan membuat prediksi yang akurat.

Pengujian Jumlah data: Untuk mengetahui bagaimana perubahan presentase jumlah data latih yang digunakan berdampak pada hasil akurasi.

Berikut ini adalah hasil penelitian pelatihan LVQ yang didasarkan pada data yang ada dan berbagai variabel tentang teknik LVQ [9].

3.1 Pengujian akurasi pada pembagian data 70%:30%

Pada pengujian metode LVQ menggunakan pembagian data 70% data latih dan 30% data uji terdapat beberapa hasil akurasi, didapatkan hasil akurasi tertinggi sebesar 80.00% yaitu pada Tabel 3 percobaan pelatihan pembelajaran $\alpha = 0.2$, $dec \alpha = 0.001$ dan epoch 500.

Tabel 3 Hasil pelatihan data 70%:30%

Dec α	α	Epoch	Tingkat akurasi (%)
0.001	0.1	100	71.43
	0.2	500	80.00
	0.3	700	77.14
	0.5	800	57.14
	0.9	1000	42.86
0.01	0.1	100	68.57
	0.2	500	65.71
	0.3	700	65.71
	0.5	800	57.14
	0.9	1000	57.14

0.1	0.1	100	65.71%
	0.2	500	65.71%
	0.3	700	65.71%
	0.5	800	57.14%
	0.9	1000	57.14%

3.2 Pengujian akurasi pada pembagian data 80%:20%

Pada pengujian metode LVQ menggunakan pembagian data 80% data latih dan 20% data uji terdapat beberapa hasil akurasi, didapatkan hasil akurasi tertinggi sebesar 82.61% yaitu pada Tabel 4 percobaan pelatihan pembelajaran $\alpha = 0.2$, $dec \alpha = 0.001$ dan epoch 500.

Tabel 4 Hasil pelatihan data 80%:20%

Dec α	α	Epoch	Tingkat akurasi (%)
0.001	0.1	100	69.57
	0.2	500	82.61
	0.3	700	78.26
	0.5	800	56.52
	0.9	1000	43.48
0.01	0.1	100	60.87
	0.2	500	60.87
	0.3	700	60.87
	0.5	800	56.52
	0.9	1000	56.52
0.1	0.1	100	60.87
	0.2	500	60.87
	0.3	700	60.87
	0.5	800	56.52
	0.9	1000	56.52

3.3 Pengujian akurasi pada pembagian data 90%:10%

Pada pengujian metode LVQ menggunakan pembagian data 90% data latih dan 10% data uji terdapat beberapa hasil akurasi, didapatkan hasil akurasi tertinggi sebesar 83.33% yaitu pada Tabel 5 percobaan pelatihan pembelajaran $\alpha = 0.1$, $dec \alpha = 0.001$ dan epoch 1000.

Tabel 5 Hasil pelatihan data 90%:10%

Dec α	α	Epoch	Tingkat akurasi (%)
0.001	0.1	1000	83.33
	0.2	500	75.00
	0.3	700	75.00
	0.5	800	41.67
	0.9	100	58.33
0.01	0.1	1000	58.33
	0.2	500	58.33
	0.3	700	58.33
	0.5	800	41.67
	0.9	100	58.33
0.1	0.1	1000	58.33
	0.2	500	58.33
	0.3	700	58.33
	0.5	800	41.67
	0.9	100	41.67

4. KESIMPULAN

Berikut ini adalah hasil dari penelitian yang dilakukan:

1. Pada proses pembelajaran, simulasi model klasifikasi LVQ mencapai tingkat akurasi tertinggi sebesar 83,33% dengan pembagian data latih sebanyak 90% dan 10% data uji dengan parameter $dec \alpha$ sebesar 0,001 dan α sebesar 0,1.
2. Parameter yang digunakan dalam metode LVQ, seperti $dec \alpha$, α , dan epoch, berdampak pada tingkat akurasi.
3. Semakin banyak data latih yang digunakan, semakin akurat hasil simulasi.

5. SARAN

Untuk meningkatkan kualitas studi penelitian ini, ada beberapa saran yang dapat diimplementasikan. Pertama, disarankan untuk mempertimbangkan penggunaan data perbandingan dengan jaringan syaraf tiruan lain atau metode yang berbeda. Hal ini akan membantu dalam menguji keandalan dan kinerja model yang dikembangkan, serta memberikan pemahaman yang lebih mendalam tentang perbandingan dengan pendekatan lain yang ada. Kedua, dianjurkan untuk mengumpulkan lebih banyak data untuk mendukung analisis dan generalisasi hasil. Dengan memiliki dataset yang lebih besar, dapat memberikan representasi yang lebih baik dari variasi dalam fenomena yang diteliti, sehingga hasil yang diperoleh dapat menjadi lebih solid dan reliabel.

UCAPAN TERIMA KASIH

Selama proses penelitian dan penyusunan jurnal ini, Penulis ingin mengucapkan terima kasih kepada Tuhan Yang Maha Esa, dosen pembimbing, kedua orang tua serta rekan-rekan yang telah memberikan dukungan, bimbingan, dan semangat. Pencapaian ini tidak akan pernah terjadi tanpa rahmat, cinta, bimbingan, kekuatan, dan arahan-Nya. Penulis juga mengucapkan terima kasih kepada Tim Redaksi Jurnal Teknik Politeknik Negeri Sriwijaya yang telah memberi kesempatan, sehingga artikel ilmiah ini dapat diterbitkan.

DAFTAR PUSTAKA

- [1] R. Kumar, P. Saha, S. Sahana, dan A. Dubey, "A REVIEW ON DIABETES MELLITUS: TYPE1 & TYPE2," 2020, doi: 10.20959/wjpps202010-17336.
- [2] S. Wang *dkk.*, "Low-fouling CNT-PEG-hydrogel coated quartz crystal microbalance sensor for saliva glucose detection," *RSC Adv*, vol. 11, no. 37, hlm. 22556–22564, Jun 2021, doi: 10.1039/d1ra02841c.
- [3] S. Klein, A. Gastaldelli, H. Yki-Järvinen, dan P. E. Scherer, "Why does obesity cause diabetes?," *Cell Metabolism*, vol. 34, no. 1. Cell Press, hlm. 11–20, 4 Januari 2022. doi: 10.1016/j.cmet.2021.12.012.
- [4] "InfoTekJar: Jurnal Nasional Informatika dan Teknologi Jaringan", doi: 10.30743/infotekjar.v6i1.3913.
- [5] S. N. H. Sheikh Abdullah *dkk.*, "Round Randomized Learning Vector Quantization for Brain Tumor Imaging," *Comput Math Methods Med*, vol. 2016, 2016, doi: 10.1155/2016/8603609.
- [6] M. Aldia Abilisa, I. R. Magdalena, dan S. Sa'idah, "IDENTIFIKASI JENIS KULIT MANUSIA MENGGUNAKAN METODE GLCM DAN LVQ BERBASIS ANDROID."
- [7] N. Aliyanti, R. Ratianingsih, dan J. W. Puspita, "Sistem Pendukung Keputusan Untuk Mendeteksi Penyakit Diabetes Melitus Tipe 2 Menggunakan Metode Learning Vector Quantization (LVQ)," *JURNAL ILMIAH MATEMATIKA DAN TERAPAN*, vol. 17, no. 2, hlm. 150–159, Nov 2020, doi: 10.22487/2540766x.2020.v17.i2.15336.

-
- [8] Arnita, M. S. Sinaga, dan Elmanani, "Classification and diagnosis of diabetic with neural network algorithm learning vector quantization (LVQ)," dalam *Journal of Physics: Conference Series*, Institute of Physics Publishing, Apr 2019. doi: 10.1088/1742-6596/1188/1/012091.
- [9] E. Pandu Cynthia dan M. Imam Arifandy, "Pengelompokan Diabetic Macular Edema Berbasis Citra Retina Mata Menggunakan Fuzzy Learning Vector Quantization (FLVQ)," *Jurnal Sains, Teknologi dan Industri*, vol. 19, no. 1, hlm. 75–80, 2021.
- [10] R. Hamidi, M. Tanzil Furqon, dan B. Rahayudi, "Implementasi Learning Vector Quantization (LVQ) untuk Klasifikasi Kualitas Air Sungai," 2017. [Daring]. Tersedia pada: <http://j-ptiik.ub.ac.id>
- [11] T. Addabbo, A. Fort, E. Landi, R. Moretti, M. Mugnaini, dan V. Vignoli, "Strategies for the Accurate Measurement of the Resonance Frequency in QCM-D Systems via Low-Cost Digital Techniques," *Sensors*, vol. 22, no. 15, Agu 2022, doi: 10.3390/s22155728.
- [12] S.-J. Young *dkk.*, "Multi-Walled Carbon Nanotubes Decorated with Silver Nanoparticles for Acetone Gas Sensing at Room Temperature," *J Electrochem Soc*, vol. 167, no. 16, hlm. 167519, Des 2020, doi: 10.1149/1945-7111/abd1be.
- [13] "Carbon Nanotube Biosensor for Diabetes Disease." [Daring]. Tersedia pada: <http://www.cjmb.org>
- [14] Misbah, M. Rivai, dan F. Kurniawan, "Diabetes Detection Using Carbon Nanomaterial Coated QCM Gas Sensors and a Convolutional Neural Network through Urine Sample," *International Journal of Intelligent Engineering and Systems*, vol. 16, no. 5, hlm. 417–427, 2023, doi: 10.22266/ijies2023.1031.36.
- [15] Misbah, M. Rivai, dan F. Kurniawan, "Quartz crystal microbalance based electronic nose system implemented on Field Programmable Gate Array," *Telkomnika (Telecommunication Computing Electronics and Control)*, vol. 17, no. 1, hlm. 370–376, Feb 2019, doi: 10.12928/TELKOMNIKA.v17i1.10133.
- [16] F. Zhang *dkk.*, "Application of Quantum Genetic Optimization of LVQ Neural Network in Smart City Traffic Network Prediction," *IEEE Access*, vol. 8, hlm. 104555–104564, 2020, doi: 10.1109/ACCESS.2020.2999608.
- [17] E. Setyowati dan S. Mariani, "Penerapan Jaringan Syaraf Tiruan dengan Metode Learning Vector Quantization (LVQ) Untuk Klasifikasi Penyakit Infeksi Saluran Pernapasan Akut (ISPA). PRISMA, Prosiding Seminar Nasional Matematika," vol. 4, hlm. 514–523, 2021, [Daring]. Tersedia pada: <https://journal.unnes.ac.id/sju/index.php/prisma/>