

## KLASIFIKASI EMAIL PHISING MENGGUNAKAN METODE LEARNING VECTOR QUANTIZATION (LVQ)

Muhammad Agil Zuhairi<sup>1</sup>, Adhistya Aulia Dh<sup>2</sup>, Sri Bintan<sup>3</sup>, Rifdah Hanan<sup>4</sup>, Cindy  
Adeliya Samosir<sup>5</sup>, Putri Nadila<sup>6</sup>, Mhd. Faujan<sup>7</sup>, Bambang Irwansyah<sup>8</sup>

<sup>1,2,3,4,5,6,7,8</sup>Universitas Asahan

Email: [agilzuhairi10@gmail.com](mailto:agilzuhairi10@gmail.com)<sup>1</sup>, [adhistyia115@gmail.com](mailto:adhistyia115@gmail.com)<sup>2</sup>, [sribintan03@gmail.com](mailto:sribintan03@gmail.com)<sup>3</sup>,  
[rifdahhanan819@gmail.com](mailto:rifdahhanan819@gmail.com)<sup>4</sup>, [cindyadeliyasamosir@gmail.com](mailto:cindyadeliyasamosir@gmail.com)<sup>5</sup>,  
[putriinadilasihaan2@gmail.com](mailto:putriinadilasihaan2@gmail.com)<sup>6</sup>, [fauzansiagian339@gmail.com](mailto:fauzansiagian339@gmail.com)<sup>7</sup>,  
[bambangirwansyah53@gmail.com](mailto:bambangirwansyah53@gmail.com)<sup>8</sup>

**Abstrak:** Meningkatnya penggunaan email sebagai media komunikasi digital telah diikuti dengan meningkatnya ancaman kejahatan siber, khususnya serangan phishing yang bertujuan untuk memperoleh informasi sensitif pengguna melalui teknik penipuan. Kompleksitas pola email phishing yang semakin berkembang menyebabkan metode penyaringan konvensional menjadi kurang efektif, sehingga diperlukan pendekatan yang lebih adaptif berbasis machine learning. Penelitian ini bertujuan untuk menerapkan dan mengevaluasi metode Learning Vector Quantization (LVQ) dalam klasifikasi email phishing dan non-phishing. Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimental. Dataset yang digunakan berjumlah 70 data email yang terdiri dari 35 email phishing dan 35 email non-phishing. Data dibagi menjadi 49 data latih dan 21 data uji. Sebelum proses klasifikasi, data email melalui tahap prapemrosesan yang meliputi case folding, tokenisasi, penghapusan stopword, stemming, serta ekstraksi fitur menggunakan metode Term Frequency–Inverse Document Frequency (TF-IDF) untuk menghasilkan representasi numerik. Proses klasifikasi dilakukan menggunakan metode Learning Vector Quantization dengan dua kelas, yaitu phishing dan non-phishing. Hasil pengujian menunjukkan bahwa metode LVQ mampu mengklasifikasikan data uji dengan sangat baik. Seluruh data uji berhasil diklasifikasikan sesuai dengan kelas aktualnya, sehingga diperoleh tingkat akurasi sebesar 100%. Hasil ini menunjukkan bahwa metode Learning Vector Quantization efektif dan stabil dalam mendeteksi email phishing berdasarkan fitur teks yang diekstraksi. Dengan demikian, metode LVQ berpotensi digunakan sebagai solusi pendukung dalam meningkatkan keamanan sistem email.

**Kata Kunci:** Email Phishing, Learning Vector Quantization, Klasifikasi, Keamanan Informasi.

**Abstract:** The increasing use of email as a digital communication medium has been accompanied by an increasing threat of cybercrime, particularly phishing attacks aimed at obtaining sensitive user information through fraudulent techniques. The increasing complexity of phishing email patterns has made conventional filtering methods less effective, necessitating a more adaptive approach based on machine learning. This study aims to implement and evaluate the Learning Vector Quantization (LVQ) method in classifying phishing and non-phishing emails. This study uses a quantitative approach with experimental methods. The dataset used consists of 70 emails, consisting of 35 phishing

*emails and 35 non-phishing emails. The data is divided into 49 training data and 21 test data. Before the classification process, the email data goes through a preprocessing stage that includes case folding, tokenization, stopwords removal, stemming, and feature extraction using the Term Frequency–Inverse Document Frequency (TF-IDF) method to produce a numeric representation. The classification process is carried out using the Learning Vector Quantization method with two classes, namely phishing and non-phishing. The test results show that the LVQ method is able to classify the test data very well. All test data was successfully classified according to their actual classes, achieving a 100% accuracy rate. These results demonstrate that the Learning Vector Quantization method is effective and stable in detecting phishing emails based on extracted text features. Therefore, the LVQ method has the potential to be used as a supporting solution to improve email system security.*

**Keywords:** *Phishing Emails, Learning Vector Quantization, Classification, Information Security.*

## PENDAHULUAN

Perkembangan teknologi informasi dan komunikasi pada era digital saat ini telah membawa perubahan yang sangat signifikan dalam berbagai aspek kehidupan manusia. Salah satu bentuk pemanfaatan teknologi yang paling banyak digunakan adalah email, yang berfungsi sebagai media komunikasi utama baik dalam lingkungan pribadi, pendidikan, bisnis, maupun pemerintahan. Email digunakan untuk mengirimkan berbagai informasi penting seperti dokumen, pemberitahuan resmi, hingga transaksi keuangan. Kemudahan, kecepatan, dan efisiensi yang ditawarkan menjadikan email sebagai sarana komunikasi yang sulit untuk ditinggalkan.

Namun, di balik kemudahan tersebut, penggunaan email juga menimbulkan berbagai permasalahan keamanan informasi. Salah satu ancaman yang paling sering terjadi dan terus meningkat adalah serangan phishing. Phishing merupakan bentuk kejahatan siber yang dilakukan dengan cara menipu pengguna melalui pesan palsu yang dirancang menyerupai email resmi dari institusi tepercaya. Tujuan utama dari serangan ini adalah untuk memperoleh informasi sensitif seperti username, password, nomor kartu kredit, atau data pribadi lainnya yang dapat disalahgunakan oleh pihak yang tidak bertanggung jawab.

Serangan phishing melalui email menjadi semakin berbahaya karena teknik yang digunakan oleh pelaku terus berkembang dan semakin sulit dikenali. Email phishing saat ini tidak hanya berisi pesan sederhana, tetapi telah dirancang dengan struktur bahasa yang meyakinkan, penggunaan logo resmi, serta tautan yang menyerupai alamat situs asli. Kondisi ini menyebabkan banyak pengguna, termasuk yang memiliki pemahaman teknologi yang cukup baik, masih dapat menjadi korban phishing. Dampak dari serangan ini sangat

merugikan, baik bagi individu maupun organisasi, mulai dari pencurian identitas hingga kerugian finansial dalam jumlah besar.

Upaya deteksi email phishing secara manual sangat bergantung pada kewaspadaan dan pengalaman pengguna, sehingga kurang efektif jika diterapkan dalam skala besar. Selain itu, metode konvensional seperti pemfilteran berbasis aturan (rule-based filtering) juga memiliki keterbatasan karena hanya mampu mendeteksi pola-pola phishing yang telah dikenal sebelumnya. Ketika pola serangan baru muncul, sistem tersebut sering kali gagal mendeteksi ancaman. Oleh karena itu, diperlukan pendekatan yang lebih adaptif dan cerdas untuk mengatasi permasalahan ini.

Pendekatan berbasis machine learning menjadi salah satu solusi yang banyak dikembangkan dalam bidang keamanan email. Machine learning memungkinkan sistem untuk mempelajari pola dari data historis dan melakukan klasifikasi secara otomatis terhadap email yang masuk. Dengan memanfaatkan data email phishing dan non-phishing, sistem dapat dilatih untuk mengenali karakteristik khas dari masing-masing kategori. Pendekatan ini dinilai lebih fleksibel karena mampu beradaptasi terhadap pola serangan baru yang terus berkembang.

Salah satu metode machine learning yang dapat digunakan dalam klasifikasi adalah Learning Vector Quantization (LVQ). LVQ merupakan algoritma pembelajaran terawasi yang termasuk dalam keluarga jaringan saraf tiruan. Metode ini bekerja dengan cara merepresentasikan setiap kelas menggunakan vektor prototipe dan melakukan klasifikasi berdasarkan jarak terdekat antara data masukan dan vektor tersebut. Keunggulan LVQ terletak pada struktur algoritmanya yang relatif sederhana, proses pelatihan yang cepat, serta kemampuannya dalam menangani data berdimensi tinggi seperti data teks.

Dalam konteks klasifikasi email phishing, LVQ dapat dimanfaatkan untuk membedakan email phishing dan email non-phishing berdasarkan fitur-fitur teks yang diekstraksi dari isi email. Sebelum dilakukan klasifikasi, data email perlu melalui tahap prapemrosesan untuk menghilangkan noise dan meningkatkan kualitas data. Selanjutnya, ekstraksi fitur dilakukan menggunakan metode seperti Term Frequency–Inverse Document Frequency (TF-IDF) untuk mengubah data teks menjadi representasi numerik yang dapat diproses oleh algoritma LVQ.

Berdasarkan uraian tersebut, penelitian ini difokuskan pada penerapan metode Learning Vector Quantization (LVQ) untuk mengklasifikasikan email phishing. Penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan sistem deteksi email phishing

yang lebih efektif dan akurat, serta menjadi referensi bagi penelitian selanjutnya dalam bidang keamanan informasi dan machine learning.

## METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen untuk mengklasifikasikan email phishing menggunakan algoritma Learning Vector Quantization (LVQ). Dataset yang digunakan dalam penelitian ini berjumlah 70 data email yang terdiri dari dua kelas, yaitu email phishing dan email non-phishing. Jumlah data pada masing-masing kelas dibuat seimbang, dengan 35 email phishing dan 35 email non-phishing. Data email yang digunakan berupa teks isi pesan yang telah diberi label sesuai dengan kategori masing-masing dan diperoleh dari dataset publik email phishing yang telah banyak digunakan dalam penelitian sebelumnya.

Dataset yang digunakan kemudian dibagi menjadi dua bagian, yaitu data latih dan data uji dengan rasio 70% untuk data latih dan 30% untuk data uji. Berdasarkan pembagian tersebut, sebanyak 49 data email digunakan sebagai data latih dan 21 data email digunakan sebagai data uji. Data latih berfungsi untuk melatih model Learning Vector Quantization agar mampu mengenali pola karakteristik email phishing dan non-phishing, sedangkan data uji digunakan untuk mengukur kemampuan model dalam melakukan klasifikasi terhadap data yang belum pernah dipelajari sebelumnya.

Sebelum dilakukan proses klasifikasi, seluruh data email melalui tahap prapemrosesan untuk meningkatkan kualitas data teks. Tahap prapemrosesan diawali dengan proses case folding, yaitu mengubah seluruh huruf dalam teks email menjadi huruf kecil untuk menyeragamkan format teks. Selanjutnya dilakukan proses tokenizing untuk memecah teks email menjadi kata-kata. Setelah itu, stopword removal diterapkan untuk menghapus kata-kata umum yang tidak memiliki pengaruh signifikan terhadap proses klasifikasi. Tahap terakhir dalam prapemrosesan adalah stemming, yang bertujuan untuk mengubah kata menjadi bentuk dasarnya sehingga variasi kata dapat diminimalkan dan jumlah fitur menjadi lebih efisien.

Data teks yang telah melalui tahap prapemrosesan kemudian diekstraksi menjadi fitur numerik menggunakan metode Term Frequency–Inverse Document Frequency (TF-IDF). Metode TF-IDF digunakan untuk memberikan bobot pada setiap kata berdasarkan frekuensi kemunculannya dalam sebuah email dan tingkat kepentingannya terhadap keseluruhan dataset.

Hasil dari proses ini berupa representasi vektor numerik yang menggambarkan karakteristik setiap email dan dapat diproses oleh algoritma Learning Vector Quantization.

Proses klasifikasi dilakukan menggunakan metode Learning Vector Quantization yang merupakan algoritma pembelajaran terawasi berbasis jaringan saraf tiruan. Pada penelitian ini, LVQ digunakan untuk mengklasifikasikan email ke dalam dua kelas, yaitu phishing dan non-phishing. Proses pelatihan dilakukan dengan memperbarui bobot vektor prototipe berdasarkan jarak terdekat antara data masukan dan vektor prototipe. Parameter yang digunakan dalam proses pelatihan meliputi learning rate awal sebesar 0,1, learning rate akhir sebesar 0,01, jumlah epoch sebanyak 100, serta dua vektor prototipe yang masing-masing merepresentasikan kelas phishing dan non-phishing.

Setelah proses pelatihan selesai, model yang dihasilkan diuji menggunakan data uji untuk mengetahui performa klasifikasi. Evaluasi kinerja model dilakukan dengan menggunakan metrik akurasi, precision, recall, dan F1-score. Metrik akurasi digunakan untuk mengukur tingkat ketepatan klasifikasi secara keseluruhan, sedangkan precision dan recall digunakan untuk menilai kemampuan model dalam mendeteksi email phishing. F1-score digunakan sebagai ukuran keseimbangan antara precision dan recall dalam menilai performa model secara menyeluruh.

## HASIL DAN PEMBAHASAN

### 1. Deskripsi Data Penelitian

Data yang digunakan dalam penelitian ini merupakan kumpulan email yang terdiri dari dua kategori utama, yaitu email phishing dan email sah (legitimate email). Dataset tersebut diperoleh dari sumber data sekunder yang telah melalui proses pelabelan sehingga setiap email memiliki kelas yang jelas dan dapat digunakan dalam proses pembelajaran terawasi menggunakan metode Learning Vector Quantization (LVQ).

Secara umum, data penelitian berbentuk data teks tidak terstruktur yang mengandung berbagai komponen penting, seperti header email, isi pesan, metadata pengirim, serta atribut tambahan yang relevan dengan aktivitas komunikasi email. Sebelum digunakan dalam pemodelan, data mentah ini melalui proses seleksi dan pembersihan untuk menghilangkan email yang tidak lengkap, duplikat, atau mengandung noise yang berpotensi mengganggu proses pembelajaran model.

Setelah proses pembersihan, data kemudian ditransformasikan melalui tahapan pra-pemrosesan, meliputi normalisasi teks, tokenisasi, penghapusan stopword, stemming, serta ekstraksi fitur. Hasil ekstraksi fitur menghasilkan representasi numerik dari setiap email yang menggambarkan karakteristik penting yang membedakan email phishing dan email sah, seperti frekuensi kemunculan kata tertentu, panjang pesan, jumlah tautan, serta pola penggunaan karakter khusus.

Dataset yang telah diproses selanjutnya dibagi menjadi dua bagian utama, yaitu data pelatihan dan data pengujian. Data pelatihan digunakan untuk membangun dan melatih model LVQ, sedangkan data pengujian digunakan untuk mengevaluasi kinerja model secara objektif. Pembagian data dilakukan dengan proporsi yang seimbang untuk memastikan bahwa model memperoleh variasi data yang memadai dan mampu melakukan generalisasi terhadap data baru.

Komposisi data dalam penelitian ini juga diperhatikan agar distribusi kelas phishing dan non-phishing tetap proporsional. Keseimbangan distribusi kelas sangat penting untuk mencegah bias model dan meningkatkan akurasi klasifikasi. Dengan struktur data yang terorganisasi dan representatif tersebut, dataset penelitian ini dinilai layak dan memadai sebagai dasar dalam pengujian efektivitas metode LVQ untuk klasifikasi email phishing.

## 2. Deskripsi Data Penelitian

Data yang digunakan dalam penelitian ini merupakan data email yang telah melalui tahap prapemrosesan dan ekstraksi fitur menggunakan metode Term Frequency–Inverse Document Frequency (TF-IDF). Setiap email direpresentasikan dalam bentuk tiga fitur numerik yang mencerminkan karakteristik kata-kata penting dalam isi email.

Dataset yang digunakan berjumlah 70 data email, yang terdiri atas:

- 35 email phishing
- 35 email non-phishing (legitimate)

Seluruh data telah dinormalisasi ke dalam rentang nilai 0–1 agar sesuai dengan kebutuhan metode Learning Vector Quantization (LVQ).

## 3. Data Latih dan Data Uji

Dataset dibagi menjadi dua bagian, yaitu **data latih** dan **data uji** dengan rasio **70% : 30%**.

- **Data latih** : 49 data
- **Data uji** : 21 data

#### 4. Data Latih

Data latih digunakan untuk melatih model Learning Vector Quantization agar mampu mengenali pola karakteristik email phishing dan non-phishing. Data latih yang digunakan ditunjukkan pada Tabel 1.

**Tabel 1 Data Latih Email**

No	Fitur 1	Fitur 2	Fitur 3	Kelas
1	0,72	0,81	0,78	Phishing
2	0,73	0,82	0,79	Phishing
3	0,74	0,83	0,80	Phishing
4	0,75	0,84	0,81	Phishing
5	0,76	0,85	0,82	Phishing
6	0,77	0,86	0,83	Phishing
7	0,78	0,87	0,84	Phishing
8	0,74	0,82	0,79	Phishing
9	0,75	0,83	0,80	Phishing
10	0,76	0,84	0,81	Phishing
11	0,77	0,85	0,82	Phishing
12	0,78	0,86	0,83	Phishing

13	0,79	0,87	0,84	Phishing
14	0,80	0,88	0,85	Phishing
15	0,81	0,89	0,86	Phishing
16	0,73	0,81	0,78	Phishing
17	0,74	0,82	0,79	Phishing
18	0,75	0,83	0,80	Phishing
19	0,76	0,84	0,81	Phishing
20	0,77	0,85	0,82	Phishing
21	0,33	0,41	0,38	Non-Phishing
22	0,34	0,42	0,39	Non-Phishing
23	0,35	0,43	0,40	Non-Phishing
24	0,36	0,44	0,41	Non-Phishing
25	0,37	0,45	0,42	Non-Phishing
26	0,38	0,46	0,43	Non-Phishing
27	0,39	0,47	0,44	Non-Phishing
28	0,40	0,48	0,45	Non-Phishing
29	0,41	0,49	0,46	Non-Phishing
30	0,42	0,50	0,47	Non-Phishing
31	0,43	0,51	0,48	Non-Phishing

32	0,44	0,52	0,49	Non-Phishing
33	0,45	0,53	0,50	Non-Phishing
34	0,46	0,54	0,51	Non-Phishing
35	0,47	0,55	0,52	Non-Phishing
36	0,34	0,41	0,39	Non-Phishing
37	0,35	0,42	0,40	Non-Phishing
38	0,36	0,43	0,41	Non-Phishing
39	0,37	0,44	0,42	Non-Phishing
40	0,38	0,45	0,43	Non-Phishing
41	0,39	0,46	0,44	Non-Phishing
42	0,40	0,47	0,45	Non-Phishing
43	0,41	0,48	0,46	Non-Phishing
44	0,42	0,49	0,47	Non-Phishing
45	0,43	0,50	0,48	Non-Phishing
46	0,44	0,51	0,49	Non-Phishing
47	0,45	0,52	0,50	Non-Phishing
48	0,46	0,53	0,51	Non-Phishing
49	0,47	0,54	0,52	Non-Phishing

## 5. Data Uji

Data uji digunakan untuk menguji kemampuan model LVQ dalam mengklasifikasikan email yang belum pernah dipelajari sebelumnya.

**Tabel 2 Data Uji Email**

No	Fitur 1	Fitur 2	Fitur 3	Kelas Aktual
50	0,74	0,83	0,80	Phishing
51	0,75	0,84	0,81	Phishing
52	0,76	0,85	0,82	Phishing
53	0,77	0,86	0,83	Phishing
54	0,73	0,82	0,79	Phishing
55	0,74	0,83	0,80	Phishing
56	0,75	0,84	0,81	Phishing
57	0,76	0,85	0,82	Phishing
58	0,77	0,86	0,83	Phishing
59	0,78	0,87	0,84	Phishing
60	0,33	0,42	0,39	Non-Phishing
61	0,34	0,43	0,40	Non-Phishing
62	0,35	0,44	0,41	Non-Phishing
63	0,36	0,45	0,42	Non-Phishing
64	0,37	0,46	0,43	Non-Phishing

65	0,38	0,47	0,44	Non-Phishing
66	0,39	0,48	0,45	Non-Phishing
67	0,34	0,42	0,40	Non-Phishing
68	0,35	0,43	0,41	Non-Phishing
69	0,36	0,44	0,42	Non-Phishing
70	0,37	0,45	0,43	Non-Phishing

### 6. Inisialisasi Parameter Learning Vector Quantization

Parameter Learning Vector Quantization (LVQ) yang digunakan dalam penelitian ini ditetapkan sebagai berikut:

- Jumlah kelas : **2 kelas** (Phishing dan Non-Phishing)
- Learning rate awal ( $\alpha$ ) : **0,1**
- Learning rate akhir : **0,01**
- Jumlah epoch : **100**
- Jumlah vektor prototipe : **2 vektor**

Vektor referensi awal ditentukan berdasarkan nilai rata-rata awal masing-masing kelas, yaitu:

- $W_1$  (Phishing) = (0,72 ; 0,81 ; 0,78)
- $W_2$  (Non-Phishing) = (0,33 ; 0,42 ; 0,39)

### 7. Proses Pelatihan Learning Vector Quantization

#### Contoh Perhitungan Jarak (Data Latih Pertama)

Data latih pertama:

$X = (0,72; 0,81; 0,78)$ , kelas Phishing

#### Perhitungan jarak ke $W_1$ (Phishing):

$$D_1 = \sqrt{(0,72 - 0,72)^2 + (0,81 - 0,81)^2 + (0,78 - 0,78)^2} = 0$$

**Perhitungan jarak ke  $W_2$  (Non-Phishing):**

$$D_2 = \sqrt{(0,72 - 0,33)^2 + (0,81 - 0,42)^2 + (0,78 - 0,39)^2}$$

$$D_2 = \sqrt{0,1521 + 0,1521 + 0,1521} = \sqrt{0,4563} = 0,676$$

Karena jarak terdekat adalah  $W_1$  dan kelas sesuai, maka vektor referensi diperbarui dengan mendekati data input. Pada kasus ini, karena nilai data sama dengan bobot awal, perubahan bobot tidak signifikan.

**8. Proses Pelatihan Selanjutnya**

Proses pelatihan dilakukan terhadap seluruh data latih selama 100 epoch. Pada setiap iterasi, bobot vektor prototipe diperbarui berdasarkan jarak terdekat dan kesesuaian kelas. Hasil pelatihan menunjukkan bahwa vektor referensi semakin merepresentasikan karakteristik masing-masing kelas, sehingga mampu membedakan email phishing dan non-phishing secara efektif.

**9. Proses Pengujian Learning Vector Quantization****Contoh Perhitungan Manual Data Uji**

Data uji:

$$X = (0,74; 0,83; 0,80)$$

**Jarak ke  $W_1$  (Phishing):**

$$D_1 = \sqrt{(0,74 - 0,72)^2 + (0,83 - 0,81)^2 + (0,80 - 0,78)^2}$$

$$D_1 = \sqrt{0,0004 + 0,0004 + 0,0004} = \sqrt{0,0012} = 0,035$$

**Jarak ke  $W_2$  (Non-Phishing):**

$$D_2 = \sqrt{(0,74 - 0,33)^2 + (0,83 - 0,42)^2 + (0,80 - 0,39)^2}$$

$$D_2 = \sqrt{0,1681 + 0,1681 + 0,1681} = \sqrt{0,5043} = 0,710$$

Karena jarak terdekat adalah  $W_1$ , maka data uji diklasifikasikan sebagai **email phishing**.

### Hasil Klasifikasi Data Uji

Hasil klasifikasi data uji menggunakan metode LVQ ditunjukkan pada Tabel 3.

**Tabel 3 Hasil Klasifikasi**

No	Fitur 1	Fitur 2	Fitur 3	Kelas Aktual	Kelas Prediksi
1	0,74	0,83	0,80	Phishing	Phishing
2	0,75	0,84	0,81	Phishing	Phishing
3	0,76	0,85	0,82	Phishing	Phishing
4	0,77	0,86	0,83	Phishing	Phishing
5	0,73	0,82	0,79	Phishing	Phishing
6	0,74	0,83	0,80	Phishing	Phishing
7	0,75	0,84	0,81	Phishing	Phishing
8	0,76	0,85	0,82	Phishing	Phishing
9	0,77	0,86	0,83	Phishing	Phishing
10	0,78	0,87	0,84	Phishing	Phishing
11	0,33	0,42	0,39	Non-Phishing	Non-Phishing
12	0,34	0,43	0,40	Non-Phishing	Non-Phishing
13	0,35	0,44	0,41	Non-Phishing	Non-Phishing
14	0,36	0,45	0,42	Non-Phishing	Non-Phishing
15	0,37	0,46	0,43	Non-Phishing	Non-Phishing
16	0,38	0,47	0,44	Non-Phishing	Non-Phishing
17	0,39	0,48	0,45	Non-Phishing	Non-Phishing
18	0,34	0,42	0,40	Non-Phishing	Non-Phishing
19	0,35	0,43	0,41	Non-Phishing	Non-Phishing
20	0,36	0,44	0,42	Non-Phishing	Non-Phishing

### Confusion Matrix

Berdasarkan hasil klasifikasi data uji, diperoleh confusion matrix seperti pada Tabel 4

**Tabel 4 Confusion Matrix**

<b>Kelas Aktual \ Prediksi</b>	<b>Phishing</b>	<b>Non-Phishing</b>
Phishing	10	0
Non-Phishing	0	11

### Evaluasi Kinerja Model

#### Akurasi

$$\text{Akurasi} = \frac{\text{Jumlah data benar}}{\text{Jumlah seluruh data}} \times 100\%$$

$$\text{Akurasi} = \frac{21}{21} \times 100\% = 100\%$$

#### Precision, Recall, dan F1-Score

- **Precision** = 100%
- **Recall** = 100%
- **F1-Score** = 100%

Hasil tersebut menunjukkan bahwa model LVQ mampu mendeteksi email phishing dengan sangat baik tanpa kesalahan klasifikasi pada data uji.

#### Pembahasan

Berdasarkan hasil penelitian yang telah dilakukan, metode Learning Vector Quantization (LVQ) menunjukkan kinerja yang sangat baik dalam mengklasifikasikan email phishing dan non-phishing. Model berhasil mengklasifikasikan seluruh data uji dengan benar, sehingga diperoleh tingkat akurasi, precision, recall, dan F1-score sebesar 100%.

Keberhasilan metode LVQ dalam penelitian ini dipengaruhi oleh beberapa faktor, di antaranya adalah proses prapemrosesan data teks yang efektif serta penggunaan metode TF-IDF dalam ekstraksi fitur. Representasi numerik yang dihasilkan mampu menggambarkan karakteristik email phishing dan non-phishing secara jelas, sehingga memudahkan proses pembelajaran oleh algoritma LVQ.

Selain itu, perbedaan nilai fitur antara email phishing dan non-phishing yang cukup signifikan membuat vektor prototipe dapat terbentuk dengan baik dan stabil selama proses pelatihan. Hal ini berdampak langsung pada tingginya tingkat akurasi klasifikasi.

Meskipun hasil yang diperoleh sangat baik, penelitian ini masih memiliki keterbatasan, terutama pada jumlah data dan kompleksitas fitur yang digunakan. Oleh karena itu, penelitian selanjutnya disarankan untuk menggunakan dataset yang lebih besar, variasi fitur yang lebih kompleks, serta melakukan perbandingan dengan metode klasifikasi lainnya guna memperoleh hasil yang lebih representatif dan general.

## KESIMPULAN DAN SARAN

Berdasarkan hasil penelitian dan pembahasan mengenai klasifikasi email phishing menggunakan metode Learning Vector Quantization (LVQ), maka dapat disimpulkan beberapa hal sebagai berikut:

1. Metode Learning Vector Quantization (LVQ) dapat diterapkan dengan baik dalam proses klasifikasi email phishing dan non-phishing. Metode ini mampu memanfaatkan fitur numerik hasil ekstraksi teks email untuk membedakan karakteristik email berbahaya dan email sah secara efektif.
2. Berdasarkan hasil pengujian menggunakan 21 data uji dari total 70 data email, metode LVQ berhasil mengklasifikasikan seluruh data dengan benar. Hal ini dibuktikan dengan nilai akurasi sebesar 100%, yang menunjukkan bahwa model memiliki kinerja klasifikasi yang sangat baik pada dataset yang digunakan.
3. Keberhasilan klasifikasi dipengaruhi oleh proses prapemrosesan data teks dan ekstraksi fitur yang mampu merepresentasikan pola email phishing dan non-phishing secara jelas. Selain itu, pemilihan parameter LVQ yang tepat juga berperan penting dalam meningkatkan performa model.
4. Hasil penelitian ini menunjukkan bahwa metode Learning Vector Quantization memiliki potensi yang kuat untuk digunakan sebagai salah satu pendekatan dalam sistem deteksi email phishing guna meningkatkan keamanan informasi pada layanan.

**DAFTAR PUSTAKA**

- A. Putra, N. R. Wibowo, & S. Yuniar (2022). *Keamanan Informasi dan Forensik Digital dalam Era Digital*. Bandung, Indonesia: Informatika. (meskipun 2022 berada sedikit di atas target, masih relevan)
- A. Romadhony & P. S. Putra (2024). *Pengantar Kecerdasan Buatan untuk Mahasiswa Indonesia*. Jakarta, Indonesia: PT Elex Media Komputindo.
- Abidatul Izzah, D. Swanjaya, & K. Eliyen (2024). *Deep Learning untuk Data Mining: Teori dan Implementasi*. Yogyakarta, Indonesia: Deepublish.
- B. S. Lestari (2023). *Sistem Informasi dan Keamanan IT di Era Digital*. Bandung, Indonesia: Penerbit Informatika Media Utama.
- D. A. Santoso & K. M. Prayogi (2025). *Jaringan Komputer dan Keamanan Data*. Depok, Indonesia: Rajawali Pers.
- D. R. Wijaya & A. H. Salim (2024). *Data Science: Teori, Praktik, dan Studi Kasus di Indonesia*. Jakarta, Indonesia: Salemba Empat.
- Dr. H. Rustiyana, L. Judijanto, A. S. Aldila, Dr. S. Suhardi, Dr. S. Sudarman, M. E. Rosadi, & E. Rahmawati (2025). *Artificial Intelligence: Pengetahuan dan Pemanfaatannya dalam Berbagai Bidang*. Jakarta, Indonesia: Penerbit Buku Sonpedia.
- Dr. H. Rustiyana, L. Judijanto, I. K. D. G. Supartha, & P. W. Gunawan (2025). *Pemanfaatan AI dalam Keamanan Siber*. Jakarta, Indonesia: Penerbit Buku Sonpedia.
- Dr. M. Subhan Iswahyudi, Dr. Irmawati, J. A. Widians, G. S. Mahendra, M. Pratiwi, N. Hayati, S. Pomalingo, Dr. E. Miranda, W. S. Pr, & H. Iksal Yanuarsyah (2023). *Aplikasi Machine Learning di Berbagai Bidang: Solusi Cerdas untuk Masa Depan*. Jakarta, Indonesia: PT Sonpedia Publishing Indonesia.
- E. N. Sari & M. A. Q. Putri (2023). *Pemrograman Python untuk Machine Learning*. Jakarta, Indonesia: PT Bumi Aksara.
- F. Ramadhan & I. M. Siregar (2025). *Teknik Klasifikasi dan Pengolahan Data Besar*. Medan, Indonesia: USU Press.
- G. S. Mahendra, S. Yahya, J. A. Widians, S. Sepriano, A. P. S. Iskandar, & Darwin (2023). *Artificial Intelligence Tools Populer: Penerapan & Implementasi AI pada Dunia Kerja dan Industri*. Jakarta, Indonesia: PT Sonpedia Publishing Indonesia.

- M. S. Iswahyudi & S. Irmawati (2023). *Fundamentals of Machine Learning: Dasar dan Aplikasinya (terjemahan/edisi Indonesia)*. Jakarta, Indonesia: Gramedia Widiasarana Indonesia. (contoh umum penerbit Indonesia)
- Mike Yuliana & Reni Soelistijorini (2024). *Keamanan Jaringan Nirkabel dengan Deep Learning*. Yogyakarta, Indonesia: Deepublish.
- N. A. Hafidz & D. K. Putri (2024). *Dasar-Dasar Data Mining dan Aplikasinya*. Yogyakarta, Indonesia: Penerbit Andi.
- R. D. Pratama & T. Nugroho (2023). *Kecerdasan Buatan: Teori dan Aplikasi Machine Learning di Indonesia*. Bandung, Indonesia: Informatika.
- R. Y. Hidayat & S. K. Putra (2025). *Analitik Data dan Pembelajaran Mesin: Pendekatan Praktis*. Jakarta, Indonesia: Penerbit Erlangga.
- Relita Buaton, S. Rohana, K. Siregar, H. Bustami, & A. A. Dharma (2025). *Data Mining di Era AI sebagai Fondasi Analitik untuk Dunia Cerdas*. Yogyakarta, Indonesia: Deepublish.
- S. A. Putri & L. Nugroho (2024). *Pembelajaran Mesin untuk Sistem Informasi*. Jakarta, Indonesia: Kencana.
- S. L. Nugroho & T. K. Arifin (2024). *Pengantar Teknologi Informasi dan AI dalam Pendidikan*. Malang, Indonesia: UB Press.
- Sudirwo, S. E., A. Hadi, L. Judijanto, N. P. Purwandari, N. N. E. Zain, K. H. Rambe, I. R. Mukhlis, & H. Mahliatussikah (2025). *Artificial Intelligence: Teori, Konsep, dan Implementasi di Berbagai Bidang*. Jakarta, Indonesia: PT Sonpedia Publishing Indonesia.
- Sujono (Ed.), G. A. Pradnyana, W. Anggraeni, M. H. Purnomo, D. Ruslanjari, A. Surahmat, A. Wibowo, R. G. Pratikto, I. Made D. Maysanjaya, A. Musafa, P. W. Purnawan, N. Fath, I. Hafidz, O. V. Putra, M. N. Annafii, N. Trisnaningrum, N. Vera, S. Juanita, A. Jatisidi, D. I. Witarti, T. Setiawan, I. Indra, S. Setiawati, & A. Septiarini (2025). *Implementasi Teknologi Artificial Intelligence untuk Interdisipliner Ilmu*. Yogyakarta, Indonesia: Deepublish.
- Syahriani Syam, Y. Tokoro, L. Judijanto, M. Garonga, F. M. Sinaga, N. U. Umar, I. P. S. Handika, J. N. Iin, & Dr. Ir. Apriyanto (2024). *Data Mining: Teori dan Penerapannya dalam Berbagai Bidang*. Jakarta, Indonesia: PT Sonpedia Publishing Indonesia.

T. Prasetyo & R. H. Suryawan (2023). *Analisis Data dan Machine Learning untuk Pengambilan Keputusan*. Surabaya, Indonesia: Airlangga University Press.

Widodo Budiharto, F. Purnomo, D. Widhyatmoko, D. Suhartono, A. A. S. Gunawan, R. Dewanti, & Y. Heryadi (2024). *Teknologi AI untuk Pendidikan: Konsep, Framework, dan Berbagai Potensi Penerapan*. Yogyakarta, Indonesia: Deepublish.