

NUTRICHIVE: APLIKASI MOBILE UNTUK DETEKSI BAHAN MAKANAN DAN REKOMENDASI RESEP GUNA MENGURANGI LIMBAH MAKANAN

Agung Muhammad Albaehaqi^{1*}, Mohammad Indra Andriana², Raisman Hadi Hidayat³

^{1,2,3} Teknik Informatika, Universitas Mayasari Bakti; Jalan Tamansari Blok Rahayu I, Kel. Sukahurip, Kec. Tamansari, Kota Tasikmalaya 46191; (0265) 3199031

Received: 2 Januari 2025

Accepted: 14 Januari 2025

Published: 20 Januari 2025

Keywords:

Limbah makanan,
TensorFlow Lite,
Pembelajaran mesin,
Rekomendasi resep

Correspondent Email:

agungmuhammadalbaehaqi199@gmail.com

Abstrak. Masalah limbah makanan merupakan tantangan global yang signifikan, khususnya di Indonesia dengan tingkat kehilangan makanan mencapai 23–48 juta ton per tahun. Penelitian ini bertujuan untuk mengembangkan aplikasi berbasis mobile bernama NutriChive, yang menggunakan teknologi pembelajaran mesin untuk mendeteksi bahan makanan dari gambar sisa makanan dan memberikan rekomendasi resep. Aplikasi ini dikembangkan dengan pendekatan rekayasa perangkat lunak berbasis iterasi, menggunakan TensorFlow Lite untuk penerapan model pembelajaran mesin. Dataset yang digunakan mencakup 36 kelas bahan makanan dengan teknik augmentasi data untuk meningkatkan variasi. Pengujian menunjukkan bahwa model deteksi bahan makanan mencapai akurasi lebih dari 90% dengan waktu respon rata-rata kurang dari 2 detik. Selain itu, desain antarmuka pengguna yang intuitif memungkinkan navigasi yang mudah bagi berbagai kalangan pengguna. Hasil penelitian ini menunjukkan bahwa NutriChive efektif dalam mendukung pengurangan limbah makanan melalui pemanfaatan teknologi berbasis aplikasi.

Abstract. Food waste is a significant global challenge, especially in Indonesia, where food loss levels reach 23–48 million tons per year. This study aims to develop a mobile application called NutriChive, which utilizes machine learning technology to detect food ingredients from leftover images and provide recipe recommendations. The application was developed using an iterative software engineering approach, employing TensorFlow Lite for machine learning model implementation. The dataset includes 36 food ingredient classes with data augmentation techniques to enhance variation. Testing shows that the food ingredient detection model achieves over 90% accuracy with an average response time of less than 2 seconds. Additionally, the intuitive user interface design facilitates easy navigation for diverse user groups. The results demonstrate that NutriChive effectively supports food waste reduction through the utilization of application-based technology.

1. PENDAHULUAN

Masalah limbah makanan yang meresap dan beragam merupakan tantangan global yang signifikan yang memerlukan upaya segera dan bersama untuk penyelesaian dalam skala internasional[1]. Seperti yang disorot oleh data

statistik yang disebarluaskan oleh Kementerian Perencanaan Pembangunan Nasional (Bappenas) pada tahun 2021, bangsa Indonesia bergulat dengan besarnya kehilangan dan limbah makanan yang mengkhawatirkan, diperkirakan berkisar antara 23 hingga 48 juta

ton per tahun, yang berarti rata-rata sekitar 7,3 kilogram per individu per tahun untuk sayuran dan sekitar 5 kilogram per individu per tahun berkaitan dengan buah-buahan[2]. Pemborosan makanan yang substansif dan dapat dihindari ini tidak hanya menimbulkan dampak ekonomi yang cukup besar, tetapi juga memainkan peran penting dalam memperburuk pemanasan global, sehingga menimbulkan ancaman signifikan bagi ketahanan pangan dan kesejahteraan gizi penduduk.

Menanggapi dilema mendesak ini, banyak inisiatif telah dilaksanakan dengan tujuan mengurangi limbah makanan, yang mencakup tetapi tidak terbatas pada meningkatkan kesadaran publik mengenai implikasi limbah makanan, pengembangan teknologi pengelolaan limbah makanan canggih, dan promosi strategi inovatif untuk pemanfaatan produk makanan yang mungkin dibuang. Di antara solusi menarik yang sedang dieksplorasi adalah pembuatan aplikasi seluler yang dirancang untuk membantu pengguna dalam mengubah bahan makanan sisa menjadi kreasi kuliner yang lezat dan bermanfaat secara nutrisi.

Upaya penelitian sebelumnya telah berhasil merekayasa aplikasi yang mampu mengidentifikasi barang belanjaan secara akurat berdasarkan gambar bahan makanan sisa, sehingga memfasilitasi penyediaan beragam resep yang dapat secara efektif memanfaatkan sisa-sisa tersebut. Selain itu, desain aplikasi ini memprioritaskan keramahan pengguna, memastikan bahwa individu dapat menavigasi antarmuka dengan mudah, pada akhirnya memberdayakan pengguna untuk secara signifikan mengurangi limbah makanan dengan cara yang praktis dan efisien.

Tujuan utama dari inisiatif penelitian saat ini adalah untuk mengembangkan aplikasi baru yang dijuluki "NutriChive," yang bertujuan untuk tidak hanya mendeteksi nama-nama barang belanjaan dari foto-foto sisa makanan tetapi juga untuk menawarkan sejumlah besar resep yang dapat memfasilitasi pemanfaatan kreatif dari kelebihan bahan makanan tersebut, semua sambil mempertahankan antarmuka yang dapat diakses dan ramah pengguna. Ini adalah aspirasi dari aplikasi ini untuk memainkan peran penting dalam mengurangi tingkat limbah makanan, meningkatkan efisiensi pemanfaatan sumber daya, dan

membina lingkungan yang mendorong inovasi kuliner dan eksperimen di antara pengguna.

2. TINJAUAN PUSTAKA

2.1. Google Cloud Platform

Google Cloud Platform (GCP) mewakili lingkungan komputasi awan yang canggih dan beragam yang mengharuskan penerapan praktik penjadwalan pekerjaan yang sangat efisien di samping strategi alokasi sumber daya yang cermat untuk mencapai kinerja operasional dan pengiriman layanan yang optimal. Investigasi ilmiah ini menyelidiki penerapan Algoritma Genetik (GA), kelas teknik pengoptimalan yang terinspirasi oleh prinsip-prinsip seleksi alam, sebagai pendekatan metodologis yang menjanjikan yang bertujuan untuk meningkatkan metrik kinerja dan efisiensi pemanfaatan sumber daya dalam kerangka GCP melalui alokasi tugas yang bijaksana dan efektif ke sumber daya yang tersedia[3].

2.2. Compute Engine

Compute Engine, yang merupakan layanan integral yang disediakan oleh Google Cloud Platform, memfasilitasi pengembangan, manajemen, dan pengoperasian mesin virtual, sehingga menghadirkan banyak keuntungan seperti peningkatan skalabilitas, ketersediaan tinggi yang kuat, langkah-langkah keamanan yang ketat, dan penghematan biaya yang signifikan dengan meniadakan kebutuhan untuk infrastruktur server yang nyata, sekaligus meningkatkan kecepatan akses dan produktivitas keseluruhan di segudang lingkungan komputasi[4].

2.3. Nginx

Nginx merupakan server web yang dapat menerima peningkatan melalui penggabungan protokol keamanan seperti NAXSI, yang berfungsi sebagai Web Application Firewall (WAF) yang direkayasa untuk melindungi terhadap banyak ancaman cyber dengan merekam lalu lintas HTTP dengan cermat dan menghalangi permintaan jahat, sehingga menjamin kemanjuran server yang konsisten[5].

2.4. Machine Learning

Pembelajaran Mesin merupakan domain khusus dalam bidang kecerdasan buatan yang lebih luas, memungkinkan sistem komputasi untuk membedakan pola dalam kumpulan data untuk tujuan seperti prediksi, klasifikasi, rekomendasi, dan pengelompokan, sehingga

meningkatkan kemanjuran pemecahan masalah di beragam aplikasi praktis[6].

2.5. TensorFlow

TensorFlow adalah kerangka kerja pembelajaran mesin sumber terbuka yang digunakan dalam makalah untuk mengembangkan sistem penyaringan email spam. Ini memungkinkan jaringan saraf yang dalam untuk ekstraksi dan klasifikasi fitur, meningkatkan kinerja sistem dan kemampuan beradaptasi terhadap taktik spam yang berkembang[7].

2.6. TensorFlow Lite

TensorFlow Lite adalah kerangka kerja kuat yang dirancang untuk menerapkan model pembelajaran mesin pada perangkat yang terbatas sumber daya[8], seperti smartphone dan mikrokontroler. Ini mengoptimalkan model melalui teknik seperti kuantisasi, yang mengurangi ketepatan bobot dan aktivasi dari floating-point ke nilai integer, secara signifikan mengurangi ukuran model dan tuntutan komputasi. TensorFlow Lite Converter memfasilitasi proses ini dengan mengubah model TensorFlow standar menjadi format yang cocok untuk aplikasi seluler dan tertanam, menerapkan berbagai strategi pengoptimalan.

2.7. Github

GitHub adalah platform khusus bagi developer yang terinspirasi dari cara kerja para programmer, yang memungkinkan hosting dan peninjauan kode, pengelolaan proyek, dan pembangunan perangkat lunak secara kolaboratif dengan lebih dari 56 juta pengguna di seluruh dunia. Fungsinya mencakup manajemen proyek, sistem versioning kode, dan platform jaringan sosial bagi developer, sehingga memudahkan mereka dalam mengembangkan karya secara efisien dan terorganisir[9].

2.8. Kotlin

Kotlin adalah bahasa pemrograman modern berdasarkan Java Virtual Machine (JVM), yang dikenal karena sintaksnya yang ringkas dan keamanan nol yang ditingkatkan. Ini telah diadopsi oleh Google sebagai bahasa pilihan untuk pengembangan Android, memenuhi kebutuhan pengembang secara efektif[10].

2.9. Figma

Figma adalah alat desain grafis yang dirancang untuk membuat prototipe dan mengedit grafik vektor. Alat ini mendukung fungsionalitas off-grid melalui aplikasi desktop

yang kompatibel dengan sistem operasi Mac dan Windows. Selain itu, Figma dapat diakses melalui perangkat seluler Android dan iOS menggunakan aplikasi Figma Mirror, yang memungkinkan pengguna melihat prototipe secara real-time di perangkat mereka. Fokus utama Figma adalah desain antarmuka pengguna (UI) dan pengalaman pengguna (UX), serta mendukung kolaborasi secara real-time. Secara keseluruhan, Figma merupakan alat desain digital yang ideal untuk merancang situs web, aplikasi, atau komponen antarmuka pengguna yang dapat dengan mudah diintegrasikan ke dalam berbagai proyek[11].

3. METODE PENELITIAN

3.1. Pendekatan Penelitian

NutriChive dikembangkan dengan pendekatan rekayasa perangkat lunak berbasis iterasi, yang mencakup analisis kebutuhan, desain sistem, implementasi, dan pengujian[12]. Proses ini dirancang untuk memastikan aplikasi dapat memenuhi tujuan utamanya, yaitu mengurangi limbah makanan melalui teknologi pengenalan gambar dan rekomendasi resep.

3.2. Dataset dan Model Pembelajaran Mesin

Dataset yang digunakan adalah "Fruit and Vegetable Image Recognition" dengan 36 kelas buah dan sayuran. Setiap kelas memiliki:

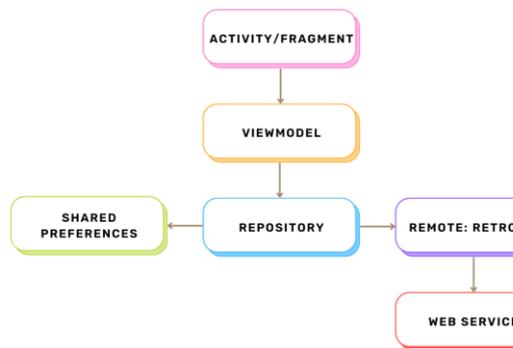
- 100 gambar untuk pelatihan.
- 10 gambar untuk validasi.
- 10 gambar untuk pengujian.

Data augmentasi dilakukan untuk meningkatkan keragaman dataset. Model pelatihan mencakup beberapa iterasi untuk mencapai akurasi optimal.

3.3. Arsitektur Aplikasi

Arsitektur NutriChive mencakup tiga komponen utama:

- **Frontend:** Dibangun menggunakan Kotlin dan Android Studio untuk memberikan antarmuka pengguna yang intuitif.



Gambar 1 Android Arsitektur

- **Backend:** Dikembangkan dengan Express.js untuk mengelola komunikasi antara aplikasi dan server.
- **Machine Learning:** Model deteksi bahan makanan diterapkan menggunakan TensorFlow Lite untuk efisiensi pada perangkat mobile.

3.4. Pengujian

Pengujian dilakukan untuk memastikan akurasi model dan fungsionalitas aplikasi. Pengujian model melibatkan evaluasi akurasi dan kehilangan (loss), sementara pengujian aplikasi meliputi pengujian fungsionalitas dan pengalaman pengguna.

4. HASIL DAN PEMBAHASAN

4.1. Hasil Implementasi

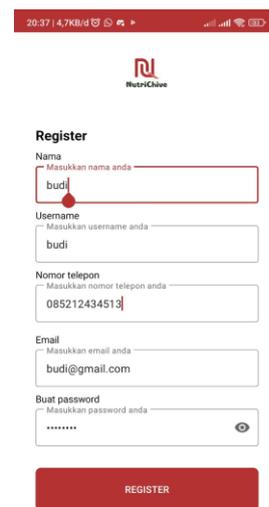
NutriChive berhasil mengintegrasikan teknologi pembelajaran mesin dan antarmuka pengguna yang ramah. Beberapa fitur utama yang telah diimplementasikan meliputi:

- **Deteksi Nama Bahan Makanan:** Model mampu mengenali bahan makanan dengan akurasi tinggi dari gambar yang diunggah pengguna.
- **Rekomendasi Resep:** Aplikasi menyediakan resep berbasis bahan makanan yang terdeteksi, membantu pengguna memanfaatkan bahan makanan sisa.
- **Antarmuka Pengguna:** Desain yang intuitif memungkinkan pengguna dari berbagai kalangan untuk

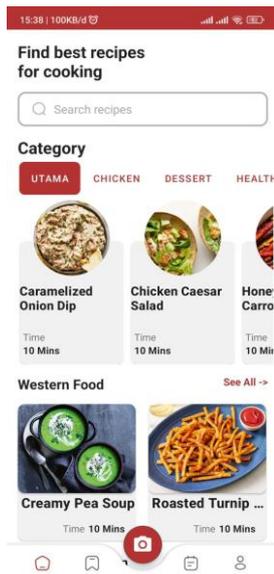
mengoperasikan aplikasi dengan mudah.



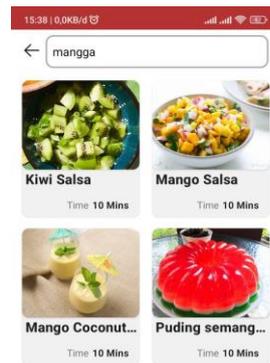
Gambar 2 Halaman Login



Gambar 3 Halaman Register



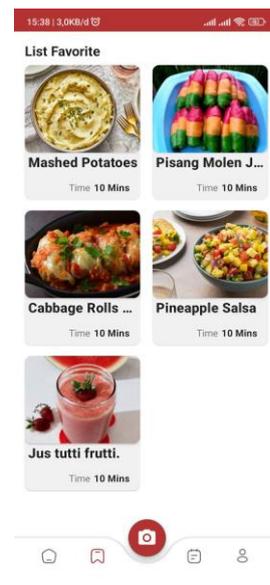
Gambar 4 Halaman Home (utama)



Gambar 6 Halaman Pencarian



Gambar 5 Halaman Detail Recipe



Gambar 7 Halaman List Favorite



Gambar 8 Halaman Ambil gambar (dari kamera atau galeri)



Gambar 9 Halaman Hasil Deteksi dan Rekomendasi Recipe

4.2. Analisis Kerja

- Akurasi Model: Model deteksi bahan makanan mencapai akurasi lebih dari 90% berdasarkan pengujian dataset validasi.
- Respon Aplikasi: Waktu respon aplikasi rata-rata berada di bawah 2 detik untuk setiap permintaan pencarian resep.

```
Epoch 41/50
196/196 [=====] - 75s 338ms/step - loss: 0.1550 - accuracy: 0.9586 - val_loss: 0.0825 - val_accuracy: 0.9772 - lr: 1.0000e-05
Epoch 42/50
196/196 [=====] - 74s 332ms/step - loss: 0.1590 - accuracy: 0.9562 - val_loss: 0.0811 - val_accuracy: 0.9772 - lr: 1.0000e-05
Epoch 43/50
196/196 [=====] - 74s 332ms/step - loss: 0.1533 - accuracy: 0.9602 - val_loss: 0.0819 - val_accuracy: 0.9715 - lr: 1.0000e-05
Epoch 44/50
196/196 [=====] - 74s 332ms/step - loss: 0.1534 - accuracy: 0.9584 - val_loss: 0.0884 - val_accuracy: 0.9715 - lr: 1.0000e-05
Epoch 45/50
196/196 [=====] - ETA: 0s - loss: 0.1464 - accuracy: 0.9620
Epoch 45: ReduceLROnPlateau reducing learning rate to 9.999999747378752e-07.
196/196 [=====] - 74s 330ms/step - loss: 0.1464 - accuracy: 0.9620 - val_loss: 0.0903 - val_accuracy: 0.9715 - lr: 1.0000e-06
Epoch 46/50
196/196 [=====] - 74s 330ms/step - loss: 0.1474 - accuracy: 0.9616 - val_loss: 0.0818 - val_accuracy: 0.9715 - lr: 1.0000e-06
Epoch 47/50
196/196 [=====] - 74s 332ms/step - loss: 0.1440 - accuracy: 0.9632 - val_loss: 0.0810 - val_accuracy: 0.9715 - lr: 1.0000e-06
Epoch 48/50
196/196 [=====] - 74s 332ms/step - loss: 0.1391 - accuracy: 0.9665 - val_loss: 0.0814 - val_accuracy: 0.9715 - lr: 1.0000e-06
Epoch 49/50
196/196 [=====] - 74s 330ms/step - loss: 0.1381 - accuracy: 0.9663 - val_loss: 0.0825 - val_accuracy: 0.9715 - lr: 1.0000e-06
Epoch 50/50
196/196 [=====] - 74s 333ms/step - loss: 0.1313 - accuracy: 0.9677 - val_loss: 0.0830 - val_accuracy: 0.9687 - lr: 1.0000e-06
```

Gambar 10 Akurasi Model

4.3. Pembahasan

4.3.1. Performa Model Deteksi

- Model pembelajaran mesin berhasil mencapai akurasi lebih dari 90% selama pengujian pada dataset validasi, menunjukkan kemampuan yang andal dalam mengenali bahan makanan dari gambar yang diunggah pengguna.
- Penurunan nilai loss selama proses pelatihan menunjukkan bahwa model semakin terlatih dalam memahami pola data.

```
model.summary()
Model: "sequential_1"
Layer (type) Output Shape Param #
-----
conv2d (Conv2D) (None, 222, 222, 64) 1792
max_pooling2d (MaxPooling2D) (None, 111, 111, 64) 0
batch_normalization (Batch Normalization) (None, 111, 111, 64) 256
conv2d_1 (Conv2D) (None, 109, 109, 128) 73856
max_pooling2d_1 (MaxPooling2D) (None, 54, 54, 128) 0
batch_normalization_1 (Batch Normalization) (None, 54, 54, 128) 512
conv2d_2 (Conv2D) (None, 52, 52, 256) 295168
max_pooling2d_2 (MaxPooling2D) (None, 26, 26, 256) 0
batch_normalization_2 (Batch Normalization) (None, 26, 26, 256) 1024
conv2d_3 (Conv2D) (None, 24, 24, 512) 1180160
```

Gambar 11 Model Summary 1

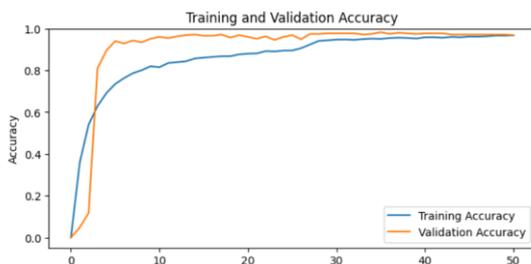
batch_normalization_3 (Batch Normalization)	(None, 12, 12, 512)	2048
conv2d_4 (Conv2D)	(None, 10, 10, 1024)	4719616
max_pooling2d_4 (MaxPooling2D)	(None, 5, 5, 1024)	0
batch_normalization_4 (Batch Normalization)	(None, 5, 5, 1024)	4096
global_max_pooling2d (GlobalMaxPooling2D)	(None, 1024)	0
dense (Dense)	(None, 36)	36900

Total params: 6315428 (24.09 MB)
 Trainable params: 6311460 (24.08 MB)
 Non-trainable params: 3968 (15.50 KB)

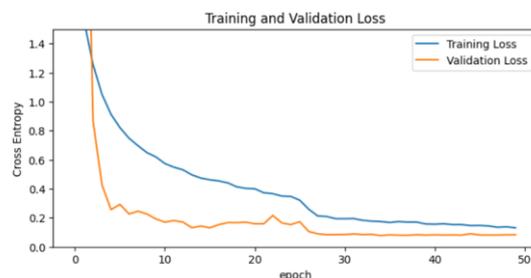
Gambar 12 Model Summary 2

4.3.2. Efisiensi Waktu Respons

Waktu rata-rata untuk memproses data hingga menghasilkan rekomendasi resep adalah di bawah 2 detik. Hal ini menunjukkan bahwa aplikasi NutriChive memberikan pengalaman pengguna yang efisien dan cepat.



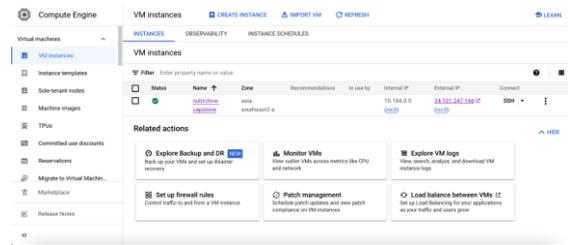
Gambar 13 Riwayat Akurasi



Gambar 14 Riwayat Loss

4.3.3. Rekomendasi Resep Berbasis Bahan Makanan

NutriChive tidak hanya mendeteksi bahan makanan, tetapi juga menyediakan rekomendasi resep yang relevan berdasarkan bahan yang terdeteksi. Hal ini membantu pengguna memanfaatkan bahan makanan sisa dengan cara yang kreatif dan praktis.



Gambar 15 Development

5. KESIMPULAN

- Aplikasi NutriChive berhasil dikembangkan dengan mengintegrasikan teknologi pembelajaran mesin menggunakan TensorFlow Lite dan antarmuka pengguna yang intuitif.
- Model deteksi bahan makanan menunjukkan akurasi tinggi, mencapai lebih dari 90% selama pengujian pada dataset validasi.
- Aplikasi memberikan waktu respons rata-rata di bawah 2 detik, menjadikannya efisien dan nyaman untuk digunakan oleh pengguna.
- Desain antarmuka yang ramah pengguna memungkinkan akses mudah ke fitur deteksi bahan makanan dan rekomendasi resep, mendukung pengurangan limbah makanan secara praktis.
- Penelitian ini memberikan kontribusi nyata dalam memanfaatkan teknologi pembelajaran mesin untuk mengatasi masalah lingkungan melalui pendekatan inovatif.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada team yang telah membantu dalam pengerjaan aplikasi ini dan pihak-pihak terkait yang telah memberi dukungan terhadap penelitian ini.

DAFTAR PUSTAKA

- [1] A. Markos, Makiso, Urugo; Tilahun, A.; Teka, Habtamu; Fikadu, Gemede; Siwan, Mersha; Ararsa, Tessema; Henock, Woldemichael Woldemariam; Habtamu, "No Title," *Compr. Rev. Food Sci. Food Saf.*, vol. 23, no. 5, 2024, doi: 10.1111/1541-4337.70011.
- [2] "https://www.geologinesia.com/2017/10/pencemaran-udara-beserta-penyebab-dan-akibatnya.html)," pp. 5–30, 2017.
- [3] P. K. Pawan Kumar, Senthil Pandi, S., "No Title," *Using Genet. Algorithms to Optim. Job*

- Sched. Google Cloud Platf.*, 2024, doi: 10.1109/icnwc60771.2024.10537412.
- [4] Á. Luz, María, Hernández, Cruz., María, José, González, Novelo., José, Ramón, Cab, Chan., Diana, Concepción, Mex, “No Title,” *Implementación la Apl. web BITA en Google Comput. Engine*, vol. 7, no. 10, pp. 107–117, 2023.
- [5] H. Muhammad, Innuddin., Pahrul, Irfan., Rifqi, “No Title,” *Meningkat. Keamanan Web Serv. Nginx dengan NAXSI sebagai Web Appl. Firewall. J. Apl. Teknol. Inf. dan Manaj.*, vol. 4, no. 2, pp. 148-156., 2023, doi: 10.31102/jatim.v4i2.2310.
- [6] L. Muflikhah, W. F. Mahmudy, and D. Kurnianingtyas, “Machine Learning,” *Mach. Learn.*, Oct. 2023, doi: 10.11594/UBPRESS9786232967694.
- [7] Rajendra Kankrale, “Tensor Flow-powered Spam Email Filtering: An Evaluation of Performance and Robustness,” *J. Electr. Syst.*, vol. 20, no. 6s, pp. 509–515, Apr. 2024, doi: 10.52783/JES.2683.
- [8] N. C. A. Sallang, M. T. Islam, M. S. Islam, and H. Arshad, “A CNN-Based Smart Waste Management System Using TensorFlow Lite and LoRa-GPS Shield in Internet of Things Environment,” *IEEE Access*, vol. 9, pp. 153560–153574, 2021, doi: 10.1109/ACCESS.2021.3128314.
- [9] Dicoding Intern, “Apa itu GitHub? Berikut Cara Menggunakannya,” dicoding. Accessed: Jan. 02, 2025. [Online]. Available: <https://www.dicoding.com/blog/apa-itu-github/>
- [10] J. Molina-Morales, L. Deng, J. Dehlinger, and S. Chakraborty, “Mutant-Kraken: A Mutation Testing Tool for Kotlin,” *2024 IEEE Int. Conf. Softw. Testing, Verif. Valid. Work.*, pp. 227–236, May 2024, doi: 10.1109/ICSTW60967.2024.00051.
- [11] W. D. P. Rahayu, A. A. Hendriadi, and T. Ridwan, “Perancangan Ui Ux Aplikasi Website Sistem Informasi Menggunakan Metode User Centered Dsign (Studi Kasus Desa Losari Kidul),” *J. Inform. dan Tek. Elektro Terap.*, vol. 12, no. 3, pp. 2952–2964, 2024, doi: 10.23960/jitet.v12i3.4994.
- [12] A. Saputri and A. M. Hirzan, “Aplikasi Manajemen Inventori Berbasis Mobile Menggunakan Flutter Dan Firebase Realtime Database,” *J. Inform. dan Tek. Elektro Terap.*, vol. 12, no. 3, pp. 1586–1592, 2024, doi: 10.23960/jitet.v12i3.4324.