

Algoritma *Backpropagation Neural Network* pada Sistem Optik Pendeteksi Kontaminan Boraks dan Formalin pada Makanan

Hafis Novianas^{1*}, Shabri Putra Wirman¹, Neneng Fitrya¹

Program Studi Fisika, Universitas Muhammadiyah Riau, Pekanbaru, Riau 28290

Info Artikel

Histori Artikel:

Diajukan: 15 November 2024

Direvisi: 8 Desember 2024

Diterima: 9 Januari 2025

Kata kunci:

Borax

Formalin

Backpropagation

Bolin Detector

Hidden Layer

Keywords:

Boraks

Formalin

Backpropagation

Bolin Detektor

Hidden Layer

Penulis Korespondensi:

Hafis Novianas

Email: novianashafis@gmail.com

ABSTRAK

Bolin Detektor adalah alat pendeteksi boraks dan formalin yang mengidentifikasi kontaminasi berdasarkan perbedaan warna, namun masih memiliki kekurangan dalam mengenali data berdasarkan kadar kontaminan. Sistem hanya mengandalkan nilai *threshold* untuk mengelompokkan data, dan beberapa titik pada data sampel memiliki nilai yang tumpang tindih sehingga sulit untuk dibedakan. Penelitian ini membangun jaringan saraf tiruan (JST) untuk meningkatkan performa Bolin Detektor. Arsitektur yang digunakan adalah *backpropagation*, dengan metode pelatihan *traingdx*, *traincgb*, *traincgf*, dan *traincgp*, serta variasi *hidden layer* dan *neuron*. Hasilnya, JST mampu mengenali 100% data pelatihan dan 97,83% data pengujian. Akurasi terbaik dicapai dengan metode *traincgb*, menggunakan 85 neuron pada *hidden layer* pertama dan 40 neuron pada *hidden layer* kedua.

*The Bolin Detector is a device designed to detect borax and formalin contamination based on color differences. However, it has limitations in recognizing data based on contaminant levels. The system relies solely on threshold values for data classification, and several data points from samples exhibit overlapping values, making it difficult to differentiate between them. This research developed an Artificial Neural Network (ANN) to improve the performance of the Bolin Detector. The architecture used is backpropagation, with training methods including *traingdx*, *traincgb*, *traincgf*, and *traincgp*, as well as variations in the number of hidden layers and neurons. The results show that the ANN can recognize 100% of the training data and 97.83% of the testing data. The best accuracy was achieved using the *traincgb* method, with 85 neurons in the first hidden layer and 40 neurons in the second hidden layer.*

Copyright © 2025 Author(s). All rights reserved

I. PENDAHULUAN

Bahan kimia bersifat esensial dalam peningkatan kesejahteraan manusia dan penggunaannya sedemikian luas di berbagai sektor antara lain industri, pertanian, pertambangan dan lain sebagainya. Hal yang perlu diwaspadai adalah adanya kecenderungan penggunaan yang salah pada sejumlah bahan berbahaya pada pangan. Masih terdapat masyarakat yang tidak mengetahui adanya produk makanan/minuman yang mengandung bahan-bahan yang berbahaya untuk dikonsumsi seperti pewarna pakaian, formalin, boraks/bleng/pijer, serta pengetahuan masyarakat terhadap obat tradisional yang mengandung bahan kimia obat masih cukup rendah (Badan POM RI, 2016).

Penelitian dan studi literatur yang dilakukan (Berliana et al., 2021) menunjukkan bahwa mengonsumsi makanan yang mengandung boraks dan formalin sangat berbahaya. Dampaknya bisa merusak hati, ginjal, dan bahkan memicu kanker. Ciri-ciri makanan tidak sehat ini adalah lebih kenyal, kering, berwarna terang, tahan lama, dan tidak berbau. Faktanya, masih banyak makanan jajanan di lingkungan Sekolah yang mengandung bahan berbahaya ini, seperti boraks, formalin, dan rhodamin-B.

Metode pengujian sampel boraks dan formalin yang umum digunakan melibatkan pengamatan perubahan warna setelah penambahan zat pengurai. Selain itu, indikator alami seperti kunyit, kulit buah naga, dan kubis ungu, serta uji bau dan tekstur, dapat memberikan petunjuk keberadaan kontaminan (Putra, 2021). Uji laboratorium dengan kromatografi atau spektrofotometri menawarkan akurasi lebih tinggi (Anngela et al., 2021). Namun, metode-metode ini seringkali rumit, memakan waktu, dan memerlukan keahlian khusus, sehingga menyulitkan masyarakat untuk melakukan pengujian langsung saat membeli makanan. Oleh karena itu, kebutuhan akan alat deteksi yang cepat, mudah, dan dapat digunakan secara mandiri menjadi sangat penting.

"Bolin Detektor" telah dirancang yang merupakan alat untuk mendeteksi bahan pangan yang mengandung boraks dan formalin dengan mudah dan cepat. Alat ini bekerja dengan memanfaatkan perbedaan intensitas warna antara pangan yang terkontaminasi dan yang tidak terkontaminasi. Bolin Detektor menggunakan sensor warna TCS34725 untuk membaca intensitas warna, menghasilkan nilai intensitas gelombang *Red*, *Green*, dan *Blue* dalam bentuk bilangan bulat positif (Gusfita, 2019). Meskipun Bolin Detektor mudah digunakan, sistemnya masih memiliki kekurangan dalam proses pengenalan data. Sistem hanya mengandalkan nilai *threshold* untuk mengelompokkan data dan tidak mampu mengenali data berdasarkan kadar kontaminan. Hal ini karena beberapa titik pada data sampel memiliki nilai yang tumpang tindih (Gusfita et al., 2019).

Jaringan Saraf Tiruan (JST) dapat menjadi solusi potensial untuk mengatasi keterbatasan Bolin Detektor, seperti yang telah diterapkan pada sistem identifikasi objek lain berbasis warna. Misalnya, sistem untuk mengidentifikasi jenis mangga berdasarkan nilai intensitas RGB. Sistem ini menggunakan pengolahan pola citra RGB dari gambar yang diambil kamera. Jaringan Saraf Tiruan (JST) dengan algoritma *backpropagation* diterapkan untuk mengklasifikasikan jenis-jenis mangga. Hasilnya, sistem mencapai tingkat akurasi rata-rata 100% pada proses pelatihan dan 95,31% pada proses pengujian (Jamaludin et al., 2021). Pendekatan JST ini dapat membantu mengatasi kekurangan Bolin Detektor dalam mengidentifikasi pola RGB, khususnya dalam mengelompokkan data kadar yang memiliki nilai tumpang tindih.

Terdapat beberapa metode yang digunakan dalam JST seperti *k-Nearest Neighbors* (k-NN), *Support Vector Machines* (SVM), atau algoritma berbasis pohon keputusan, namun memiliki keterbatasan dalam menangani data non-linear atau data tumpang tindih, yang menjadi salah satu masalah utama pada Bolin Detektor. Selain itu, metode seperti CNN atau RNN mungkin terlalu kompleks untuk kasus sederhana seperti pengelompokan berdasarkan nilai RGB. Metode yang dipilih adalah *backpropagation* karena menawarkan keseimbangan yang baik antara kesederhanaan implementasi dan kemampuan dalam mempelajari pola dari data RGB yang dihasilkan oleh Bolin Detektor. Jaringan saraf tiruan (JST) dengan metode *backpropagation* telah menjadi teknik populer di berbagai aplikasi. JST meniru cara kerja sistem saraf manusia, terdiri dari elemen pemrosesan sederhana yang terhubung secara paralel. Backpropagation adalah salah satu algoritma JST yang sederhana dengan kemampuan dan akurasi tinggi (Muhajirin & Yasir, 2024).


Penelitian ini berfokus pada pengembangan arsitektur jaringan saraf tiruan yang akan diintegrasikan ke dalam Bolin Detektor, sebuah alat pendeteksi boraks dan formalin dalam makanan. Arsitektur ini akan mengolah data RGB yang diperoleh dari sensor warna TCS34725 pada Bolin Detektor, dengan tujuan meningkatkan akurasi dan efisiensi dalam mengidentifikasi dan mengklasifikasikan kadar kontaminan boraks dan formalin dalam makanan, sehingga memberikan

informasi yang lebih akurat mengenai keamanan pangan, Alat ini diharapkan dapat membantu masyarakat dalam mendeteksi bahan berbahaya pada makanan dengan lebih efektif. Pengembangan arsitektur JST ini terbukti berhasil meningkatkan akurasi Bolin Detektor. Sebelum integrasi JST, alat ini hanya mampu mendeteksi keberadaan kontaminan tanpa informasi kadar, dengan JST *backpropagation* akurasi pengujian alat mencapai 97,83%. Ini menunjukkan peningkatan signifikan karena Bolin Detektor kini mampu mengklasifikasikan sampel berdasarkan kadar kontaminan boraks dan formalin.

II. METODE

2.1 Perancangan Arsitektur Jaringan *Backpropagation*

Arsitektur Jaringan *Backpropagation* dibangun seperti yang ditunjukkan pada Gambar 1 untuk mengenali variasi sampel primer dan sekunder dengan tiga lapisan: *input*, *hidden*, dan *output*.



Gambar 1 Arsitektur Jaringan *Backpropagation*

Arsitektur jaringan dibangun melalui proses pelatihan dan pengujian dengan berbagai parameter untuk menemukan konfigurasi terbaik. Parameter yang ditentukan meliputi jumlah layer dan neuron, metode pelatihan, fungsi aktivasi, MSE (Mean Squared Error), dan jumlah iterasi. Langkah pertama yaitu penentuan jumlah layer dan neuron. Jumlah hidden layer dimulai dengan 1 layer, kemudian ditingkatkan menjadi 2 layer untuk variasi percobaan. Jumlah neuron juga divariasikan untuk setiap konfigurasi. Selanjutnya metode pelatihan yang digunakan dalam penelitian ini adalah metode default MATLAB, *trainidx*, karena merupakan algoritma pelatihan populer dalam Jaringan Saraf Tiruan (JST) untuk pembelajaran berbasis *backpropagation* (Hamdy & Younis, 2023). Selain itu, juga dilakukan percobaan dengan metode lain: *traincgf*, *traincgp*, dan *traincgb*. Berikut adalah penjelasan singkat mengenai perbedaan masing-masing metode pelatihan:

1. *Trainidx* (*Gradient Descent with Momentum and Adaptive Learning Rate*): Variasi gradient descent dengan momentum untuk mempercepat pelatihan dan adaptive learning rate untuk penyesuaian laju pembelajaran otomatis. Umumnya menghasilkan konvergensi yang baik dan sering digunakan sebagai baseline.
2. *Traincgf* (*Conjugate Gradient with Fletcher-Reeves Updates*): Umumnya lebih cepat konvergensinya daripada gradient descent standar, tetapi mungkin memerlukan lebih banyak iterasi per epoch.
3. *Traincgp* (*Conjugate Gradient with Polak-Ribière Updates*): Seringkali lebih efisien dalam hal memori dan waktu komputasi dibandingkan *traincgf*, terutama untuk jaringan besar.
4. *Traincgb* (*Conjugate Gradient with Powell-Beale Restarts*): Membantu menghindari minimum lokal dan meningkatkan stabilitas pelatihan.


2.2 Pengumpulan Data

Proses pengumpulan data dalam penelitian ini melibatkan data primer berupa nilai RGB dari sampel ikan laut, ikan asin, dan tahu dari tiga pasar berbeda yang diuji formalin dan boraks menggunakan tes kit, serta pengambilan data RGB menggunakan Bolin Detektor dengan 20 kali pengulangan per variasi. Data sekunder diperoleh dari penelitian Gusfita (2019) yang mencakup nilai RGB dari daging sapi, daging ayam, bakso, dan lontong yang terkontaminasi formalin dan boraks,

dengan tiga variasi kadar kontaminan dan 15 kali pengulangan per variasi. Nilai RGB diukur menggunakan model warna dengan kedalaman 24-bit (Abdullah et al., 2019).

2.3 Pelatihan Arsitektur Jaringan Backpropagation

Arsitektur *backpropagation* dirancang dengan melatih data sampel yang telah dikumpulkan untuk menemukan bobot jaringan yang paling akurat. Data sampel dibagi menjadi dua bagian untuk pelatihan dan pengujian, serta dinormalisasi ke dalam rentang 0 hingga 1 sebelum pelatihan. Alur pelatihan dan pengujian dapat dilihat pada Gambar 2.



Gambar 2 Diagram Alur Pelatihan dan Pengujian

Arsitektur *backpropagation* dirancang untuk mengenali 8 jenis sampel dengan 3 variasi, di mana data primer diambil 20 kali per variasi dan dibagi menjadi 13 data untuk pelatihan serta 7 untuk pengujian, sedangkan data sekunder diambil 15 kali per variasi dan dibagi menjadi 10 data untuk pelatihan serta 5 untuk pengujian, menghasilkan total 267 data pelatihan dan 138 data pengujian (405 data keseluruhan). Proses normalisasi dilakukan dengan mentransformasikan data latih dan uji ke dalam interval 0 hingga 1 menggunakan fungsi aktivasi *sigmoid biner* dengan *range* [0.1, 0.9], karena fungsi *sigmoid* tidak pernah mencapai 0 atau 1 (Khairati & Putra, 2022). Target keluaran jaringan merupakan interpretasi input data RGB dalam bentuk bilangan biner untuk klasifikasi sampel. Pelatihan jaringan menggunakan Matlab R2012b dimulai dengan perintah $N = \text{train}(N, R, T)$, di mana R adalah *array* data input, T adalah *array* data target, dan N adalah jaringan yang dibangun untuk identifikasi boraks dan formalin. Pengujian sistem dilakukan untuk mengevaluasi akurasi pengenalan karakter, dengan akurasi ideal mencapai 100% (Putra Wirman et al., 2022). Pengujian dilakukan pada data latih, yaitu data yang telah melalui proses pelatihan sebelumnya, serta pada data uji yang diambil dari kelompok kedua tanpa proses pelatihan sebelumnya (Fitri et al., 2022).

III. HASIL DAN DISKUSI

3.1 Hasil Pengumpulan Data

Tabel 1 Hasil Uji Sampel dengan Uji Tes Cepat Kualitatif

Sampel	Kontaminasi	Hasil Identifikasi		
		Pasar Pagi Arengka	Pasar Rumbai	Pasar Pusat
Ikan Laut (HN1)	Boraks	Negatif	Negatif	Negatif
	Formalin	Positif	Negatif	Negatif
Ikan Asin (HN2)	Boraks	Negatif	Negatif	Negatif
	Formalin	Negatif	Positif	Negatif
Tahu (HN3)	Boraks	Negatif	Negatif	Negatif
	Formalin	Negatif	Positif	Negatif

Hasil pengumpulan data meliputi data primer dari sampel pasar dan data sekunder dari penelitian Gusfita (2019). Data primer mencakup identifikasi boraks dan formalin menggunakan metode tes cepat kualitatif dengan reagen spesifik, serta pengambilan nilai RGB dari sampel ikan laut, ikan asin, dan tahu dari tiga pasar di Pekanbaru (Pasar Pagi Arengka, Pasar Rumbai, dan Pasar Pusat). Hasil uji tes cepat kualitatif menunjukkan bahwa beberapa sampel mengandung formalin, namun tidak ada

sampel yang menunjukkan adanya boraks, ditandai dengan tidak adanya perubahan warna pada kertas lakmus (Sugiaty Rintjap dkk 2023). Hasilnya dapat dilihat pada tabel 1.

Data nilai RGB diambil dengan kode sampel HN1 (ikan laut), HN2 (ikan asin), dan HN3 (tahu), di mana kontaminasi boraks/formalin diberi kode tambahan "P" dan yang tanpa kontaminasi diberi kode "N". Perbedaan nilai RGB disebabkan oleh penambahan unsur baru yang memengaruhi kemampuan bahan dalam memantulkan cahaya (Fitrya et al., 2021).

3.2 Hasil Pelatihan Arsitektur Jaringan

Tabel 2 Variasi Pelatihan Terbaik dari Masing-Masing Metode

Metode Pelatihan	Variasi Terbaik		MSE	Iterasi
	Layer 1	Layer 2		
Traincgb	85	40	0,0000097	1710
Traincgf	85	40	0,0082015	5406
Traincgp	85	85	0,0000091	448
Traingdx	85	60	0,0000233	19237

Pelatihan jaringan dilakukan dengan empat metode pelatihan yang berbeda yaitu *traincgb*, *traincgf*, *traincgp*, dan *traingdx*. Setiap metode diuji dengan 10 variasi jumlah layer dan neuron. Hasil pelatihan menunjukkan performa yang bervariasi berdasarkan nilai *Mean Squared Error* (MSE) yang diperoleh. Pada tabel 2 ditampilkan ringkasan variasi jaringan terbaik berdasarkan performa (MSE) yang dihasilkan dari masing-masing metode pelatihan.

3.3 Hasil Pegujian Arsitektur Jaringan

Setelah melatih arsitektur jaringan, analisis dan pengujian dilakukan dalam dua tahap untuk menilai keakuratan performa. Pada pengujian dengan data latih, akurasi jaringan bervariasi, di mana 21 variasi pelatihan mencapai akurasi di atas 75%, didominasi oleh metode *traingdx*. Variasi terbaik adalah metode *traincgp* dengan konfigurasi Layer 1 (85 neuron) dan Layer 2 (85 neuron), yang berhasil mencapai akurasi 100% dengan nilai MSE sangat rendah. Sementara itu, pada pengujian dengan data uji, akurasi jaringan juga bervariasi, dengan 17 variasi pelatihan mencapai akurasi di atas 75%, dan metode *traincgb* dengan konfigurasi Layer 1 (85 neuron) dan Layer 2 (40 neuron) mencapai akurasi terbaik sebesar 97,83%, berhasil mengenali 135 dari 138 data uji dengan benar.


3.4 Analisis Variasi Arsitektur Jaringan Terbaik

Pemilihan metode pelatihan terbaik dalam alat pendeteksi boraks dan formalin didasarkan pada beberapa faktor utama: akurasi, jumlah iterasi, dan performa MSE. Berikut adalah pembahasan dan visualisasi dalam bentuk diagram batang untuk menunjukkan perbandingan antara metode pelatihan.

Gambar 3 (a) merupakan visualisasi dari Tabel 2 untuk membandingkan jumlah iterasi masing-masing metode. *Traincgp* membutuhkan iterasi yang lebih sedikit yaitu 448 epoch dibandingkan dengan *traincgb* yang membutuhkan rata-rata 1710 epoch. Sementara itu metode *traingdx* dan *traincgf* memiliki jumlah iterasi yang lebih besar yaitu 19237 dan 5406. Jumlah iterasi yang lebih sedikit mengindikasikan pelatihan lebih efisien, yang sangat penting dalam praktik implementasi.

Gambar 3 (b) menunjukkan *traincgp* memiliki performa MSE rata-rata yang lebih kecil (0,0000091) dibandingkan metode *traincgb* yang mencapai MSE yaitu 0,0000097. Semakin rendah MSE, maka semakin pintar jaringan yang tersusun dari neuron-neuron tersebut, menunjukkan tingkat presisi yang tinggi dalam pengenalan pola dan klasifikasi (Aisah dkk. 2022).

Setelah menganalisis ketiga parameter (iterasi, MSE, dan akurasi), *traincgb* dengan konfigurasi 85 dan 40 neuron pada layer pertama dan kedua menunjukkan performa paling optimal. Meskipun *traincgp* unggul dalam hal iterasi dan MSE yang sedikit lebih rendah, perbedaan MSE tersebut sangat kecil dan tidak signifikan secara praktis. Dalam konteks aplikasi ini, di mana akurasi prediksi lebih diutamakan daripada kecepatan pelatihan, perbedaan iterasi menjadi kurang berpengaruh. Sebaliknya, *traincgb* unggul secara signifikan dengan akurasi pengujian 97,83%, menunjukkan kemampuan generalisasi yang sangat baik untuk memprediksi data baru. Oleh karena itu, *traincgb* (85, 40) dipilih sebagai metode pelatihan terbaik untuk arsitektur JST pada Bolin Detektor.



Gambar 3 (a) Perbandingan Iterasi Masing-Masing Metode (b) Perbandingan MSE Masing-Masing Metode (c) Perbandingan Akurasi Masing-Masing Metode

IV. KESIMPULAN

Berdasarkan penelitian, arsitektur *Backpropagation Neural Network* mampu mengenali sampel dengan akurasi hingga 97,83%. Arsitektur ini menggunakan empat metode pelatihan (*trainidx*, *traincgp*, *traincgf*, dan *traincgb*) dengan variasi jumlah *neuron* dan *hidden layer*. Hasil terbaik dicapai dengan metode *traincgb* pada Layer 1 dengan 85 *neuron* dan Layer 2 dengan 40 *neuron*. Penelitian ini menunjukkan efektivitas arsitektur dalam klasifikasi sampel berdasarkan kadar boraks dan formalin 0%, 2% dan 5%.

UCAPAN TERIMA KASIH

Kami mengucapkan terima kasih kepada Laboratorium Fisika dan Instrumentasi Universitas Muhammadiyah Riau atas fasilitas dan dukungan teknis yang diberikan selama proses penelitian ini. Saudara Gusfita, atas penelitian sebelumnya yang menjadi fondasi pengembangan Bolin Detektor serta data sekunder yang sangat berharga bagi penelitian ini. Universitas Muhammadiyah Riau, khususnya Program Studi Fisika Fakultas Mipa dan Kesehatan, atas dukungan dan kesempatan yang diberikan dalam pelaksanaan penelitian ini. Semoga penelitian ini dapat memberikan kontribusi positif bagi pengembangan ilmu pengetahuan dan teknologi, serta bermanfaat bagi masyarakat luas.

DAFTAR PUSTAKA

- Abdullah, Rianto, B., & Aina, S. (2019). Prediksi Kualitas Ikan Senangin Berdasarkan Warna dan Tekstur. *Jurnal Informatika Dan Komputer*, 4(1), 35–44.
- Aisah, S. S. N., Abdullatif, F., & Hartono, H. (2022). Identifikasi frekuensi bunyi gambang laras slendro gamelan Jawa menggunakan jaringan syaraf tiruan pada Matlab. *Jurnal Teras Fisika*, 5(1), 273. <https://doi.org/10.20884/1.jtf.2022.5.1.5816>
- Akram, A., Fayakun, K., & Ramza, H. (2023). Klasifikasi Hama Serangga pada Pertanian Menggunakan Metode Convolutional Neural Network. *Building of Informatics, Technology and Science (BITS)*, 5(2), 397–406. <https://doi.org/10.47065/bits.v5i2.4063>

- Anngela, O., Muadifah, A., & Nugraha, D. P. (2021). Validasi Metode Penetapan Kadar Boraks pada Kerupuk Puli Menggunakan Spektrofotometer UV-Vis. *Jurnal Sains Dan Kesehatan*, 3(4), 375–381. <https://doi.org/10.25026/jsk.v3i4.258>
- Badan POM RI. (2016). Annual Report Indonesian National Agency of Drug and Food Control 2016. *Badan Pengawas Obat Dan Makanan Republik Indonesia*, 1–219.
- Berliana, A., Abidin, J., Salsabila, N., Maulidia, S., Adiyaksa, R., & Febryani, V. (2021). Penggunaan bahan tambahan makanan berbahaya boraks dan formalin dalam makanan jajanan : studi literatur hazardous use of food supplements of borax and formalin in snack food : Literature study. *Sanitasi Lingkungan*, 1(2), 65–71. <https://doi.org/10.36086/salink.v1i2.952>
- Fitri, Y., Retnawaty, S. Fi., & Zecha, N. (2022). Aplikasi pengenalan ucapan sebagai pengendali ac dengan ekstraksi ciri. 8(2), 23–26.
- Fitrya, N., Putra Wirman, S., & Gusfita, R. (2021). Prosiding SainsTeKes. *Prosiding Saintek Semnas MIPAKes Umri*, 2, 232–241. <https://ejurnal.umri.ac.id/index.php/Semnasmipakes/article/view/2881/1604>
- Gusfita, R. (2019). *Rancang Bangun Sistem Pendeteksi Kontaminan Boraks dan Formalin pada Makanan menggunakan Sensor TCS34725 Berbasis Android*.
- Gusfita, R., Fitrya, N., Hamzah, M., & Alwi, M. (2019). Investigasi Penggunaan Formalin Pada Makanan Menggunakan Bolin Detektor Berbasis Sensor Warna Tcs34725. *Prosiding SainsTeKes*, 34–38. <https://ejurnal.umri.ac.id/index.php/Semnasmipakes/article/view/1587>
- Hamdy, R., & Younis, M. (2023). Performance Evaluation of Artificial Neural Network Methods Based on Block Machine Learning Classification. *AL-Rafidain Journal of Computer Sciences and Mathematics*, 17(2), 111–123. <https://doi.org/10.33899/csmj.2023.142250.1079>
- Jamaludin, J., Rozikin, C., & Irawan, A. S. Y. (2021). Klasifikasi Jenis Buah Mangga dengan Metode Backpropagation. *Techne : Jurnal Ilmiah Elektroteknika*, 20(1), 1–12. <https://doi.org/10.31358/techne.v20i1.231>
- Khairati, F., & Putra, H. (2022). Prediksi Kuantitas Penggunaan Obat pada Layanan Kesehatan Menggunakan Algoritma Backpropagation Neural Network. *Jurnal Sistim Informasi Dan Teknologi*, 4, 128–135. <https://doi.org/10.37034/jsisfotek.v4i3.158>
- Muhajirin, A., & Yasir, M. (2024). *Penerapan Jaringan Saraf Tiruan Dengan Metode Backpropagation Untuk Memprediksi Tingkat Kelulusan Mahasiswa Perguruan Tinggi*. 4(1), 214–224.
- Putra, I. (2021). Identifikasi Formalin Dan Boraks Pada Produk Bakso Di Kecamatan Banyuwangi. *Jurnal Teknologi Pangan Dan Ilmu Pertanian (Jipang)*, 2(1), 21–31. <https://doi.org/10.36526/jipang.v2i1.1213>
- Putra Wirman, S., Fitrya, N., Junaidi, R., & Rizki, N. G. (2022). Rancang Bangun Sistem Pengenalan Plat Nomor Kendaraan Menggunakan Jaringan Saraf Tiruan Backpropagation. *Photon: Jurnal Sain Dan Kesehatan*, 12(2), 148–157. <https://doi.org/10.37859/jp.v12i2.2586>