

SISTEM PREDIKSI CAPAIAN HAFALAN 30 JUZ SANTRI MENGUNAKAN ARTIFICIAL NEURAL NETWORK (ANN) DENGAN ALGORITMA BACKPROPAGATION

Ranita, Adi Suwondo, Nur Hasanah

Teknik Informatika, Universitas Sains Al-Qur'an Wonosobo, Jawa Tengah, Indonesia
ranita004@mhs.unsiq.ac.id

ABSTRAK

Lembaga tahfidz Al-Qur'an merupakan pusat pembinaan hafalan yang memiliki target penyelesaian 30 juz bagi setiap santri. Penilaian perkembangan hafalan di PPTQ Nawwir Quluubanaa masih dilakukan secara manual melalui buku laporan, sehingga potensi keterlambatan pencapaian target sulit terdeteksi lebih awal. Permasalahan ini menyebabkan pengelola kesulitan memberikan pendampingan yang tepat waktu dan berbasis data. Penelitian ini bertujuan membangun sistem prediksi capaian hafalan 30 juz santri menggunakan metode *Artificial Neural Network* (ANN) dengan algoritma *backpropagation*, serta mengintegrasikannya ke dalam *dashboard* berbasis web. Data yang digunakan berasal dari 146 santri dengan lima variabel input: jumlah juz hafalan, halaman setoran per minggu, halaman muroja'ah per minggu, persentase kehadiran, dan gender. Setelah pembersihan *outlier*, tersisa 96 data yang dibagi dengan proporsi 80:20 untuk *training* dan *testing*. Model terbaik menggunakan dua *hidden layer* (32 dan 16 *neuron*), aktivasi ReLU, *dropout* 0,1, dan *learning rate* 0,01. Hasil evaluasi menunjukkan RMSE 13,7483 bulan dan MAPE 13,68%, sehingga model dikategorikan akurat (tingkat keberhasilan 86,32%) berdasarkan kriteria Lewis (1982). Sistem *dashboard* yang dibangun menggunakan Flask/Python memperoleh skor SUS 79,5 (kategori *Good*).

Kata kunci : *Prediksi hafalan, Artificial Neural Network, Backpropagation, Tahfidz, Machine Learning*

1. PENDAHULUAN

Program tahfidz Al-Qur'an merupakan salah satu kegiatan pendidikan yang memiliki peran penting dalam membentuk kualitas spiritual dan intelektual santri. Target utama dari banyak lembaga tahfidz adalah menyelesaikan hafalan 30 juz, yang menjadi indikator ketuntasan dan keberhasilan proses pembelajaran Al-Qur'an. Namun, setiap santri memiliki kemampuan dan kecepatan hafalan yang berbeda-beda, dipengaruhi oleh konsistensi menghafal, kualitas setoran, tingkat kehadiran, pola belajar, serta lingkungan pembinaan [1].

Pada kondisi nyata di PPTQ Nawwir Quluubanaa, pencatatan perkembangan hafalan 146 santri masih dilakukan secara manual melalui buku laporan hafalan santri dan rekapan bulanan. Metode tersebut membantu untuk dokumentasi, namun belum mampu memberikan gambaran mendalam mengenai kapan seorang santri diperkirakan menyelesaikan hafalan 30 juz. Lima kriteria utama yang menjadi tolak ukur keberhasilan santri yaitu jumlah juz hafalan, setoran per minggu, muroja'ah per minggu, tingkat kehadiran, dan gender menyimpan potensi informasi yang sangat berharga apabila diolah sebagai dasar prediksi. Tanpa prediksi, keterlambatan hafalan baru diketahui setelah masalah terjadi, bukan terdeteksi lebih awal. Akibatnya, pendampingan yang terlambat dapat memperpanjang masa menghafal, menurunkan motivasi, bahkan berisiko menyebabkan santri tidak menyelesaikan target hafalan sama sekali. Seiring kemajuan kecerdasan buatan, *Artificial Neural Network* (ANN) terbukti efektif dalam membangun model prediksi pada data dengan banyak variabel yang

saling memengaruhi [2]. Algoritma *backpropagation* memungkinkan ANN belajar dari data pelatihan secara iteratif dengan meminimalkan kesalahan prediksi melalui pembaruan bobot jaringan [3].

Penelitian ini membangun sistem prediksi capaian hafalan 30 juz santri menggunakan ANN dengan algoritma *backpropagation*, lalu mengintegrasikannya ke dalam *dashboard* berbasis web sehingga pengurus pesantren dapat memantau perkembangan hafalan secara terukur dan berbasis data.

2. TINJAUAN PUSTAKA

2.1. *Artificial Neural Network* (ANN)

ANN adalah salah satu komponen inti dalam perkembangan kecerdasan buatan (AI) modern yang merupakan model komputasi terinspirasi dari sistem saraf otak manusia. *Neural Network* mengadopsi kemampuan otak manusia yang mampu menerima rangsangan, melakukan proses, dan menghasilkan *output* [4]. Secara teknis, ANN merupakan alat pemodelan non-linier yang dapat menangkap hubungan kompleks antara *input* dan *output* dalam data. Model ini dibangun dari neuron buatan yang disusun dalam lapisan berjenjang, menyerupai cara kerja otak di mana bagian "*dendrit*" mewakili masukan yang dipengaruhi bobot (*weight*), "*badan sel*" melakukan komputasi, dan "*akson*" mengirimkan keluaran ke neuron berikutnya. Arsitektur ANN terdiri dari tiga lapisan utama: (1) *Input layer*, lapisan awal yang menerima data mentah dari luar setiap neuron hanya mewakili satu fitur masukan; (2) *Hidden layer*, lapisan tengah yang memproses data melalui bobot

dan fungsi aktivasi untuk menemukan pola tersembunyi bisa terdiri dari satu atau lebih lapisan sesuai kompleksitas masalah; dan (3) *Output layer*, lapisan terakhir yang menghasilkan prediksi akhir, di mana setiap neuron keluaran berkaitan dengan nilai target (nilai kontinu pada regresi atau kelas pada klasifikasi). Komponen utama ANN meliputi neuron sebagai unit pemroses, bobot yang menentukan pengaruh setiap *input*, bias yang menambah fleksibilitas model, serta fungsi aktivasi yang menghasilkan keluaran non-linear. Dalam penelitian ini, ANN digunakan untuk memodelkan hubungan antara lima variabel hafalan santri dengan estimasi waktu khatam 30 juz [4].

2.2. Algoritma Backpropagation

Backpropagation adalah algoritma yang digunakan untuk melatih jaringan saraf tiruan, khususnya dalam menghitung gradien dari fungsi kerugian terhadap bobot jaringan yang kemudian digunakan untuk memperbarui bobot tersebut. Algoritma ini menyesuaikan bobot berdasarkan selisih keluaran dan target yang diinginkan guna mengurangi nilai *error*. Proses penghitungan error antara target dan data aktual diulangi hingga error mencapai batas yang ditentukan di awal [5]. Algoritma *backpropagation* pertama kali dikembangkan pada tahun 1986 oleh Rumelhart, Hinton, dan Williams. Keunggulannya terletak pada kemampuannya belajar, adaptasi terhadap pola kompleks, dan toleransi terhadap kesalahan, sehingga cocok untuk menangani masalah dengan pola-pola yang rumit. Pelatihan dilakukan berulang dengan memberikan sepasang pola masukan dan pola target yang diinginkan, kemudian bobot-bobot diubah untuk memperkecil perbedaan pola keluaran hingga semua pola terpenuhi. Secara umum, terdapat tiga tahap utama dalam pelatihan *backpropagation*: (1) *Feedforward*, data input diteruskan lapis demi lapis dari *input layer* melalui *hidden layer* hingga menghasilkan nilai prediksi di *output layer*; (2) *Backpropagation Error*, nilai kesalahan antara keluaran prediksi dan target dihitung menggunakan turunan dari fungsi kesalahan (*gradient*), kemudian dipropagasikan mundur dari *output layer* menuju *input layer*; (3) Pembaruan Bobot, setiap bobot dan bias diperbarui berdasarkan gradien dan nilai *learning rate* menggunakan *optimizer* hingga jaringan menghasilkan keluaran yang lebih akurat. Proses ini berulang hingga nilai kesalahan mencapai batas tertentu atau model konvergen [5].

2.3. Metrik Evaluasi

Dua metrik utama yang digunakan untuk mengevaluasi performa model regresi adalah RMSE (*Root Mean Square Error*) dan MAPE (*Mean Absolute Percentage Error*). RMSE mengukur rata-rata selisih prediksi dalam satuan yang sama dengan data asli, sedangkan MAPE mengukur persentase rata-rata kesalahan prediksi. Berdasarkan kriteria Lewis (1982),

model dikategorikan akurat apabila nilai MAPE berada pada rentang 10%-20% [6].


2.4. Kajian Penelitian Terdahulu

Penelitian serupa telah dilakukan di berbagai bidang. Widhi Aryanti [7] menerapkan ANN *backpropagation* untuk prediksi harga saham dan mencapai akurasi 96% dengan RMSE 0,01128. Azhima dkk. [8] menggunakan metode yang sama untuk klasifikasi penyakit stroke dengan akurasi 96,14%. Sujjada dkk. [9] membangun sistem prediksi nilai ujian siswa berbasis web menggunakan ANN dengan arsitektur 4-64-1. Belum ada penelitian yang menerapkan ANN *backpropagation* khusus dalam konteks prediksi capaian hafalan Al-Qur'an di lingkungan pesantren, yang menjadi kebaruan dari penelitian ini.

3. METODE PENELITIAN

Penelitian ini merupakan penelitian terapan (*applied research*) dengan pendekatan kuantitatif [10]. Disebut penelitian terapan karena tujuan utamanya yaitu mengembangkan dan menerapkan model *Artificial Neural Network* (ANN) dengan algoritma *Backpropagation* untuk memecahkan masalah nyata yang dihadapi oleh PPTQ Nawwir Quluubanaa, yaitu ketidakmampuan sistem manual dalam memprediksi capaian hafalan santri secara objektif.

Penelitian ini menggabungkan tiga elemen utama sebagai dasar kerangka pemikiran. Pertama, kajian teori mengenai *Artificial Neural Network* (ANN) dan algoritma *Backpropagation* yang terbukti efektif dalam membangun model prediksi pada data dengan banyak variabel input yang saling memengaruhi. Kedua, observasi lapangan yang mengidentifikasi lima variabel kunci dalam proses hafalan santri, yaitu jumlah juz yang telah dihafal, jumlah halaman setoran per minggu, jumlah halaman muroja'ah per minggu, gender, dan tingkat kehadiran saat setoran. Ketiga, kajian pustaka yang menunjukkan bahwa ANN *Backpropagation* telah berhasil diterapkan di berbagai bidang prediksi dengan tingkat akurasi yang cukup tinggi. Berikut adalah gambar 1. menunjukkan kerangka pikir penelitian.



Gambar 1. Kerangka pikir penelitian

3.1. Data dan Variabel Penelitian

Data berasal dari 146 santri aktif PPTQ Nawwir Quluubanaa tahun 2023-2025, dikumpulkan dari buku

laporan hafalan dan rekapan bulanan pengurus. Dataset mencakup lima variabel input dan satu variabel target sebagaimana ditampilkan pada Tabel 1.

Tabel 1. Variabel input dan output dataset

Variabel	Tipe	Satuan	Keterangan
Juz_Hafal	Input(X1)	Integer	Jumlah juz yang telah dihafal saat pencatatan
Setoran (hal/minggu)	Input(X2)	Desimal	Rata-rata halaman hafalan perminggu
Murojaah (hal/minggu)	Input(X3)	Desimal	Rata-rata halaman yang diulang perminggu
Kehadiran (%)	Input(X4)	Presentasi	Kehadiran saat setoran dan murojaah
Gender	Input(X5)	Kategori	Putra=0, putri=1 (label <i>encoding</i>)
Waktu_sisa_bulan	Output(Y)	integer	Estimasi bulan yang dibutuhkan untuk menyelesaikan 30 juz

Variabel target Waktu_Sisa_Bulan tidak tersedia secara langsung di catatan pesantren, sehingga dihitung menggunakan formula berikut:

$$Waktu\ sisa = \frac{(30 - Juz\ hafal) \times 20}{\left(\frac{(Setoran \times 4) + (Murojaah \times 4)}{2} \right) \times \left(\frac{Kehadiran}{100} \right)} \quad (1)$$

Sisa halaman yang perlu dihafal (dari juz saat ini ke 30 juz, dengan asumsi 1 juz = 20 halaman) dibagi kapasitas hafalan efektif per bulan, yang diperoleh dari rata-rata setoran dan muroja'ah per minggu dan dikalikan rata-rata kehadiran. Santri yang sudah khatam langsung mendapat nilai 0 bulan; santri dengan aktivitas sangat rendah dibatasi pada nilai default 99 bulan untuk menghindari nilai tak hingga [11].

3.2. Preprocessing Data

Preprocessing terdiri dari tiga tahap berurutan. Pertama, data *cleaning*: tidak ditemukan *missing values*, namun dilakukan penghapusan baris tanpa nomor urut. Selain itu, 50 data santri dengan Waktu_Sisa_Bulan > 99 bulan diidentifikasi sebagai *outlier* ekstrem karena nilai tersebut tidak mencerminkan pola hafalan yang dapat dipelajari secara bermakna, dataset bersih berjumlah 96 santri.

Kedua, *encoding* variabel gender menggunakan label *encoding* (putra=0, putri=1). Ketiga, seluruh

variabel dinormalisasi menggunakan *min-max scaling* ke rentang 0,1-1,0 untuk menghindari nilai nol yang bermasalah pada perhitungan MAPE menggunakan rumus: [7].

$$v'_n = 0.1 + \frac{(v_n - v_{min})(1 - 0.1)}{v_{max} - v_{min}} \quad (2)$$

Rentang 0,1-1,0 dipilih untuk menghindari nilai nol yang menyebabkan error pada perhitungan MAPE. Setelah *preprocessing*, data dibagi dengan proporsi 80:20, yaitu 76 data *training* dan 20 data *testing* menggunakan *random split* dengan *random_state* tetap.

3.3. Arsitektur dan Pelatihan Model ANN

Model ANN dibangun menggunakan *framework TensorFlow/Keras* berbasis Python di Google Colab. *Hyperparameter tuning* dilakukan terhadap 8 konfigurasi yang memvariasikan jumlah neuron pada hidden layer, *dropout*, *learning rate*, dan *batch size*. Seluruh model dilatih dengan maksimum 300 epoch menggunakan mekanisme *EarlyStopping* (*patience*=30). Arsitektur final terbaik dari hasil *tuning* ditampilkan pada Tabel 2.

Tabel 2. Spesifikasi arsitektur model ANN final

Komponen	Nilai/konfigurasi	Keterangan
Neuron input	5	Juz_Hafal, Setoran, Muroja'ah, Kehadiran, Gender
Hidden layer 1	32 neuron-ReLU	Mencegah <i>vanishing gradient</i>
Hidden layer 2	16 neuron-ReLU	Pendalaman representasi fitur
Dropout	0,1	Regularisasi setelah tiap <i>hidden layer</i>
Neuron output	1-Linear	Prediksi Waktu_Sisa_Bulan
Optimizer	Adam	Adaptif untuk dataset kecil
Loss funtion	MSE	Sesuai untuk regresi
Learning rate	0,0100	Dari hasil <i>hyperparameter tuning</i>
Epoch max	300 + <i>EarlyStopping</i>	<i>patience</i> =30
Batch size	16	Dari hasil <i>hyperparameter tuning</i>

Pelatihan model menggunakan algoritma *Backpropagation* melalui tiga tahap utama yang berulang: (1) *Feedforward*: data input diteruskan dari lapisan input melewati *hidden layer* hingga menghasilkan nilai prediksi; (2) *Backpropagation Error*: selisih antara nilai prediksi dan target dihitung menggunakan MSE, kemudian dipropagasikan balik; (3) Pembaruan Bobot: bobot dan bias diperbarui

menggunakan *optimizer* Adam berdasarkan gradien dan *learning rate*.

3.4. Metrik Evaluasi

Evaluasi model menggunakan dua metrik. RMSE mengukur rata-rata besaran kesalahan dalam satuan bulan [7]:

$$RMSE = \sqrt{\frac{\sum (x_i - \hat{y}_i)^2}{n}} \quad (3)$$

MAPE mengukur persentase rata-rata kesalahan prediksi [3]:

$$MAPE = \frac{100\%}{n} \times \sum \left| \frac{x_i - \hat{y}_i}{x_i} \right| \quad (4)$$

Berdasarkan kriteria Lewis (1982): MAPE < 10% = sangat akurat, 10%-20% = akurat, 20%-50% = cukup akurat, >50% = tidak akurat [6]. Analisis *learning curve* dilakukan untuk mendeteksi *overfitting*, *underfitting* atau *good fit* [5].

3.5. Implementasi Sistem

Model terbaik diintegrasikan ke aplikasi web menggunakan *framework* Flask dengan Python [12] di sisi *backend*, serta HTML, CSS, dan Bootstrap di sisi *frontend*. Model disimpan dalam format .h5 dan

dimuat ulang saat inferensi sehingga prediksi dapat dihitung secara *real-time* ketika pengurus memasukkan data santri baru.

4. HASIL DAN PEMBAHASAN

4.1. Statistik Deskriptif Data

Dataset awal terdiri dari 146 santri (putra 11,64%, putri 88,36%). Setelah penghapusan 50 *outlier* (Waktu_Sisa_Bulan > 99 bulan), tersisa 96 data bersih. Nilai rata-rata Juz_Hafal sebesar 10,87 juz menunjukkan santri rata-rata telah menyelesaikan 36% dari target 30 juz. Rata-rata setoran 4,42 halaman/minggu dan muroja'ah 5,83 halaman/minggu. Rata-rata kehadiran hanya 31,55%, yang berarti partisipasi santri masih kurang dan perlu ditingkatkan lagi. Statistik lengkapnya ada di Tabel 3.

Tabel 3. Statistik deskriptif variabel penelitian

	Juz_hafal	Setoran	Muroja'ah	Kehadiran	Gender	Waktu_sisa_bulan
Count	146	146.00	146.00	146.00	146.00	146.00
Mean	10.87	4.42	5.83	31.55	0.88	207.10
Std dev	9.73	3.50	3.71	12.86	0.32	541.47
Min	1.00	0.50	0.00	5.00	0.00	0.00
25%	3.00	2.00	3.00	21.10	1.00	33.00
50%	7.50	3.62	4.75	28.00	1.00	74.50
75%	17.00	5.00	10.00	39.00	1.00	152.50
Max	30.00	20.00	18.75	60.00	1.00	4143.00

4.2. Hasil Hyperparameter Tuning

Hasil uji coba dari 8 konfigurasi *hyperparameter* bisa dilihat pada Tabel 4. Konfigurasi terbaik diperoleh pada percobaan ke-6 dengan MAPE 13,68% dan RMSE 13,7483 bulan, menggunakan 32 *neuron hidden layer* 1, 16 *neuron hidden layer* 2, *dropout* 0,1, *learning rate* 0,01, dan *batch size* 16.

Tabel 4. Hasil *hyperparameter tuning*

No	H1	H2	Drop out	LR	Batch	RMSE	MAPE (%)
1	16	8	0,2	0,001	16	21,1872	21,36
2	32	16	0,1	0,001	16	16,1030	18,08
3	64	32	0,1	0,001	16	19,2138	18,83
4	32	16	0,2	0,001	8	17,1432	18,20
5	32	16	0,0	0,001	16	15,8267	18,25
6	32	16	0,1	0,010	16	13,7483	13,68
7	16	8	0,1	0,0005	16	20,2720	20,10
8	64	32	0,0	0,001	32	15,9627	15,95

Perbedaan paling signifikan terlihat pada *learning rate*: konfigurasi 5 dan 6 identik, kecuali di *learning rate* (0,001 vs 0,01). Peningkatan *learning rate* dari 0,001 ke 0,01 menurunkan MAPE hampir 5 poin-dari 18,25% menjadi 13,68%. Ini menunjukkan bahwa pada dataset berukuran kecil ini, *learning rate* yang lebih besar membantu model menemukan minimum yang lebih baik.

4.3. Evaluasi Model

Evaluasi dilakukan pada 20 data uji. Hasil evaluasi ditampilkan pada Tabel 5. Nilai RMSE sebesar 13,7483 bulan menunjukkan rata-rata selisih


antara prediksi dan aktual sekitar 13,75 bulan. MAPE 13,68% dengan tingkat keberhasilan 86,32% masuk dalam kategori “Akurat” (rentang 10%-20% menurut Lewis, 1982), artinya model ini layak digunakan sebagai alat bantu prediksi.

Tabel 5. Hasil evaluasi model ANN

Metrik	Nilai	Keterangan
RMSE	13,7483 bulan	Rata-rata selisih prediksi dalam satuan bulan
MAPE	13,68%	Persentase rata-rata kesalahan prediksi
Keberhasilan	86,32%	Kategori Akurat

Nilai MAPE 13,68% masuk kategori “Akurat” (rentang 10-20%) berdasarkan Lewis (1982), yang berarti rata-rata kesalahan prediksi model hanya sekitar 13,68% dari data sebenarnya, sehingga setara dengan 13,75 bulan.

4.4. Analisis Learning Curve



Gambar 2. *Learning curve* model ANN

Berdasarkan analisis *learning curve*, nilai *training loss* dan *validation loss* keduanya menurun secara konsisten dan konvergen pada epoch ke-300, dengan *training loss* akhir 0,033160 dan *validation loss* 0,020147. Selisih yang kecil antar keduanya mengindikasikan model mencapai *good fit* tanpa indikasi *overfitting* maupun *underfitting*.

4.5. Implementasi dan Pengujian Sistem

Model ANN terbaik diintegrasikan ke dalam aplikasi web menggunakan *framework Flask* (Python) sebagai *backend*, dan *HTML*, *CSS*, *Bootstrap* sebagai *frontend*. *Dashboard* menampilkan tiga fungsi utama: (1) data perkembangan hafalan individual; (2) hasil prediksi estimasi waktu khatam 30 juz; dan (3) kategori status hafalan dengan indikator warna (hijau: 0-6 bln, biru: 7-12 bln, kuning: 13-24 bln, orange: 25-36 bln, merah: >36 bln).

Pengujian *Black Box Testing* menunjukkan seluruh fungsi sistem berjalan sesuai rencana (*input* data santri, prediksi, tampilan status, validasi input) [13]. Pengujian *usabilitas* menggunakan *System Usability Scale* (SUS) dengan lima responden, yaitu pengasuh, pengurus sie tahfidz, lurah pondok putra dan lurah pondok putri [14]. Dari hasil responden tersebut menghasilkan rata-rata skor SUS 78,5 dikategorikan 'Good' (rentang 68-80,3), menunjukkan sistem mudah digunakan dan dapat diterima pengguna.

5. KESIMPULAN DAN SARAN

Penelitian ini berhasil membangun sistem prediksi capaian hafalan 30 juz santri menggunakan ANN dengan algoritma *backpropagation*. Model terbaik menggunakan dua *hidden layer* (32 dan 16 neuron) dengan fungsi aktivasi ReLU, *dropout* 0,1, dan *learning rate* 0,01, menghasilkan RMSE 13,7483 bulan dan MAPE 13,68% (kategori Akurat, tingkat keberhasilan 86,32%). *Learning curve* menunjukkan model mencapai *good fit*. Sistem *dashboard* berbasis web yang dibangun mendapatkan skor SUS 79,5 (kategori Good).

Untuk pengembangan selanjutnya, disarankan menggunakan dataset yang lebih besar dari beberapa lembaga tahfidz agar kemampuan generalisasi model meningkat, serta memperluas fitur sistem dengan notifikasi otomatis dan pencatatan setoran harian secara digital.

DAFTAR PUSTAKA

- [1] N. 'Aisyah and L. Maknun, "Implementasi Pembelajaran Tahfidz Al-Qur'an Melalui Metode Talaqi," *Ibtida': J. Kajian Pendidik. Dasar*, vol. 2, no. 2, 2022, doi: 10.33507/ibtida.v2i2.1004.
- [2] Thorat, M., Pandit, S., & Balote, S. (2022). Artificial Neural Network: A Brief Study. *Asian Journal of Convergence in Technology*, 8(3), 12-16.
- [3] Trisianti, A. S. (2024). Implementasi Algoritma Backpropagation untuk Memprediksi Tingkatan Inflasi di Kota Malang.
- [4] Handoko, dkk. (2024). Artificial Neural Network dalam Klasifikasi Data.
- [5] B. S. Sihotang, "Penerapan ANN dengan Algoritma Backpropagation dalam Memprediksi Kelulusan Tepat Waktu Mahasiswa," *Digital Repository UNILA*, 2026.
- [6] Montano Moreno, J. J., et al. (2013). Using the R-MAPE Index as a Resistant Measure of Forecast Accuracy. *Psicothema*, 25(4), 500-506.
- [7] Widhi Aryanti and Nur Azizah Komara Rifai, "Penerapan Artificial Neural Network dengan Algoritma Backpropagation untuk Memprediksi Harga Saham," *J. Riset Statistika*, pp. 107-118, 2023, doi: 10.29313/jrs.v3i2.2953.
- [8] Azhima, M., Afrianty, I., Budianita, E., & Kurnia Gusti, S. (2024). Penerapan Metode Backpropagation Neural Network untuk Klasifikasi Penyakit Stroke. *Jurnal KLIK*, 4(6), 3013-3021.
- [9] Sujjada, A., et al. (2023). Prediksi Nilai Ujian Sekolah Siswa SMK Plus Padjadjaran Berbasis Web Menggunakan JST Backpropagation. *Jurnal Informasi dan Teknologi*, 5(2), 151-158.
- [10] UIN Sunan Ampel Surabaya, "Jasa riset terapan (applied research) untuk bisnis, BUMN, dan pemerintahan," Oct. 28, 2024. [Online]. Available: <https://uinsa.ac.id/jasa-riset-terapan-applied-research-untuk-bisnis-bumn-dan-pemerintahan> (accessed Mei. 19, 2026).
- [11] Yulherniwati, N. C. Putri, Humaira, D. Meidelfi, and Rasyidah, "Implementing Machine Learning in Students Qur'an Memorization Prediction," in *Proc. 5th Int. Seminar on Research of Information Technology and Intelligent Systems (ISRITI)*, 2022, pp. 362-368, doi: 10.1109/ISRITI56927.2022.10052808.
- [12] Prasatya, "Apa itu Flask? Panduan Membangun API dengan Flask," *Codepolitan*, 22 Mei 2024. <https://www.codepolitan.com/blog/apa-itu-flask-panduan-membangun-api-dengan-flask/> (accessed 30 Apr. 2026).
- [13] M. Jibril, "Pengujian Sistem Informasi E-Modul pada SMPN 1 Tempuling Menggunakan Black Box Testing," *J. Perangkat Lunak*, vol. 6, no. 2, pp. 327-332, 2024.
- [14] S. R. Wicaksono, *Usability Testing*, 1st ed. Malang: CV. Seribu Bintang, 2023.