



Aplikasi Cerdas Prediksi Keberlanjutan UMKM dengan *Extreme Learning Machine* dan *Power BI*

Yofhanda Septi Eirlangga¹, Aggy Pramana Gusman², Trinda farhan Satria³

¹Sistem Informasi, Universitas Adzkia,

²Sistem Komputer, fakultas Ilmu Komputer, Universitas Putra Indonesia YPTK Padang,

³Teknik Industri, Universitas Adzkia

yofhanda_se@adzkia.ac.id apagusman@gmail.com trindafarhansatria@adzkia.ac.id

Abstract

This study develops a data-driven model to predict the sustainability of MSMEs by using the Extreme Learning Machine (ELM) algorithm and presents the results in an interactive Power BI dashboard. Data from 500 MSME owners were collected through a questionnaire containing 46 indicators covering finance, innovation and digitalization, human resources, external support, business environment, entrepreneur characteristics, and sustainability label (active/inactive). After data cleaning, categorical encoding and Min–Max normalization, the dataset was split into 80% training and 20% testing. The ELM model was tuned with grid search over the number of hidden neurons, activation function, and L2 regularization. The best configuration used 46 input features, 800 hidden neurons, ReLU activation, and $L2 = 0.0001$. On the testing data, the model achieved an accuracy of 0.890, precision of 0.820, recall of 1.000 and an $F1$ -score of 0.901. A 5-fold cross-validation produced average accuracy, precision, recall and $F1$ -score of 0.820, 0.736, 1.000 and 0.847 indicates stable performance. The Power BI dashboard visualizes probability scores, risk categories and MSME profiles to support data-driven decision making. This study contributes a data-driven framework for MSME sustainability analytics and future work may add transactional data and compare other algorithms.

Keywords: MSME, sustainability, Extreme Learning Machine, machine learning, Power BI.

Abstrak

Penelitian ini mengembangkan model berbasis data untuk memprediksi keberlanjutan usaha mikro, kecil dan menengah (UMKM) menggunakan algoritma *Extreme Learning Machine* (ELM) dan menyajikan hasilnya melalui dashboard interaktif di Power BI. Data diperoleh dari 500 pelaku UMKM melalui kuesioner yang memuat 46 indikator pada dimensi keuangan, inovasi dan digitalisasi, sumber daya manusia, dukungan eksternal, lingkungan usaha, serta karakteristik pelaku, beserta satu label keberlanjutan (aktif/tidak aktif). Tahapan pra-pemrosesan meliputi pembersihan data, pengkodean variabel kategorikal, dan normalisasi Min–Max, kemudian data dibagi menjadi 80% data latih dan 20% data uji. Model ELM disetel menggunakan grid search terhadap jumlah neuron hidden, fungsi aktivasi, dan koefisien regularisasi L2. Konfigurasi terbaik menggunakan 46 fitur input, 800 neuron hidden, fungsi aktivasi ReLU, dan $L2 = 0,0001$. Pada data uji, model menghasilkan akurasi 0,890, *precision* 0,820, *recall* 1,000, dan *F1-score* 0,901. Evaluasi *5-fold cross validation* memberikan rata-rata akurasi 0,820, *precision* 0,736, *recall* 1,000, dan *F1-score* 0,847, yang menunjukkan performa model relatif stabil. Hasil prediksi diintegrasikan ke dalam *dashboard Power BI* untuk menampilkan skor probabilitas keberlanjutan, kategori risiko, dan profil UMKM secara interaktif guna mendukung pengambilan keputusan berbasis data. Penelitian ini memberikan kontribusi berupa kerangka prediksi dan visualisasi keberlanjutan UMKM berbasis data, dan ke depan dapat dikembangkan dengan menambah variabel perilaku transaksi serta membandingkan ELM dengan algoritma lain.

Kata kunci: UMKM, keberlanjutan, Extreme Learning Machine, pembelajaran mesin, Power BI.



1. Pendahuluan

Usaha mikro, kecil, dan menengah (UMKM) merupakan tulang punggung perekonomian Indonesia karena berkontribusi signifikan terhadap Produk Domestik Bruto (PDB) dan penyerapan tenaga kerja nasional [1]. Namun, keberlanjutan UMKM masih menghadapi berbagai tantangan, antara lain keterbatasan akses permodalan, rendahnya adopsi teknologi digital, kelemahan dalam pengelolaan manajemen, dan kerentanan terhadap guncangan ekonomi [2], [3]. Sejumlah kajian menegaskan bahwa kemampuan UMKM dalam beradaptasi terhadap perubahan lingkungan usaha dan memanfaatkan teknologi menjadi faktor penting untuk menjaga daya saing dan mempertahankan keberlanjutan usaha [4].

Perkembangan kecerdasan buatan dan pembelajaran mesin (*machine learning*) membuka peluang baru untuk menganalisis data UMKM secara lebih komprehensif dan prediktif. Beberapa penelitian telah menerapkan *algoritma machine learning* untuk memetakan keberlanjutan atau kinerja UMKM, dan menunjukkan bahwa pendekatan berbasis data mampu memberikan akurasi yang baik dalam mengidentifikasi potensi keberlanjutan usaha [5]. Penelitian lain mengusulkan model *data-driven* untuk memprediksi tingkat digitalisasi UMKM menggunakan kombinasi metode *clustering* dan algoritma *supervised*, yang semakin menegaskan relevansi pendekatan prediktif dalam mendukung kebijakan penguatan UMKM [6]. Di sisi lain, penerapan *machine learning* juga banyak dijumpai pada konteks risiko keuangan dan prediksi pasar, seperti analisis risiko kredit dan prediksi pergerakan mata uang, yang menunjukkan kemampuan algoritma ini dalam menangkap pola nonlinier pada data bisnis yang kompleks [7].

Dalam ranah pemodelan, *Extreme Learning Machine* (ELM) muncul sebagai salah satu algoritma yang menarik untuk tugas klasifikasi dan prediksi karena memiliki proses pelatihan yang sangat cepat dan kemampuan generalisasi yang kompetitif dibandingkan jaringan saraf konvensional [8]. Berbagai studi melaporkan bahwa ELM dan variannya efektif digunakan pada beragam permasalahan prediksi risiko dan kinerja di sektor keuangan maupun operasi bisnis [9], [10]. Karakteristik tersebut menjadikan ELM relevan untuk konteks UMKM yang umumnya memiliki keterbatasan sumber daya komputasi, tetapi membutuhkan model prediksi yang efisien dan cukup akurat untuk mendukung pengambilan keputusan.

Secara paralel, perkembangan *business intelligence* dan alat visualisasi seperti *Microsoft Power BI* memungkinkan hasil analisis data disajikan dalam bentuk dashboard interaktif yang lebih mudah dipahami oleh pengambil keputusan. Penelitian-penelitian sebelumnya menunjukkan bahwa *dashboard* berbasis Power BI dapat dimanfaatkan untuk menganalisis data penjualan, memantau indikator kinerja usaha, dan menghasilkan insight bisnis secara cepat dan terukur [11]. Pada level UMKM, visualisasi data yang ringkas dan intuitif menjadi penting karena pelaku usaha sering kali memiliki keterbatasan waktu dan kapasitas analitis untuk membaca laporan yang kompleks, sehingga representasi visual yang sederhana namun informatif dapat membantu proses pengambilan keputusan [12]. Beberapa inisiatif juga mengembangkan prototipe *business intelligence* untuk pemberdayaan UMKM di lembaga pemerintah, yang mengintegrasikan data dari berbagai unit ke dalam satu sistem dashboard terpusat [13]. Namun, sebagian besar studi tersebut masih berfokus pada analisis deskriptif atau pemantauan kinerja tanpa mengintegrasikan model prediktif yang secara eksplisit menilai keberlanjutan usaha di masa depan.

Selain itu, penelitian terbaru mengenai digitalisasi dan transformasi teknologi pada UMKM menunjukkan bahwa tingkat adopsi teknologi informasi, termasuk pemanfaatan platform digital dan analitik data, berpengaruh terhadap peningkatan kinerja dan keberlanjutan UMKM. Model-model prediksi berbasis data telah diusulkan untuk memetakan kesiapan maupun tingkat digitalisasi UMKM, tetapi belum secara spesifik mengkaji prediksi keberlanjutan yang diintegrasikan dengan mekanisme visualisasi interaktif yang dapat diakses langsung oleh pelaku UMKM dan pemangku kepentingan [14].

Berdasarkan kondisi tersebut, penelitian ini dilakukan untuk menjawab kesenjangan antara kebutuhan UMKM terhadap alat prediksi keberlanjutan yang akurat dengan ketersediaan sistem analisis yang mudah digunakan. Berbeda dengan penelitian terdahulu yang umumnya hanya berfokus pada pengembangan model *machine learning* tanpa dilengkapi *dashboard* interaktif ataupun pada pengembangan dashboard Power BI tanpa komponen prediktif keberlanjutan yang eksplisit [15], penelitian ini menawarkan kebaruan berupa kerangka terpadu yang mengombinasikan algoritma ELM sebagai *predictive engine* dengan Power BI sebagai *visualization tool* dalam konteks keberlanjutan UMKM. Pendekatan ini diharapkan dapat memberikan kontribusi akademis dengan mengisi celah kajian integrasi ELM–*business intelligence* pada domain UMKM, sekaligus kontribusi praktis melalui

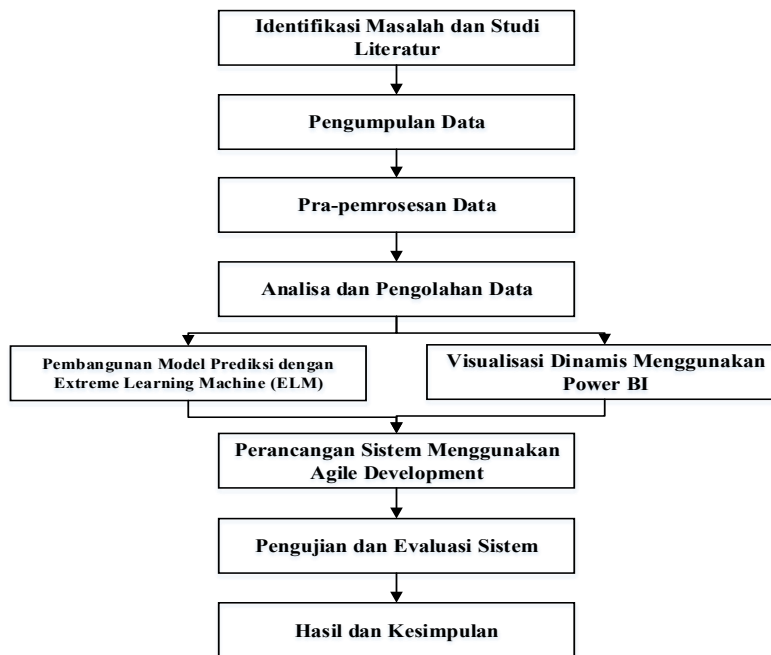
prototipe sistem prediksi keberlanjutan UMKM yang mudah diimplementasikan dan diinterpretasikan oleh pengguna non-teknis.

Sejalan dengan itu, pertanyaan utama penelitian ini adalah sejauh mana ELM mampu memprediksi keberlanjutan UMKM dengan tingkat akurasi yang memadai, dan bagaimana hasil prediksi tersebut dapat divisualisasikan secara efektif melalui *dashboard Power BI*. Tujuan penelitian adalah mengembangkan model prediksi keberlanjutan UMKM berbasis ELM, serta mengintegrasikan hasil prediksi ke dalam *dashboard* interaktif Power BI untuk mendukung pengambilan keputusan yang lebih adaptif dan berbasis data.

2. Metode Penelitian

Penelitian ini dilaksanakan dengan pendekatan kuantitatif [16] yang dikombinasikan dengan pemodelan *supervised classification* menggunakan algoritma *Extreme Learning Machine* (ELM) sebagai metode utama. Data primer dikumpulkan dari 500 pelaku UMKM di Kota Padang melalui kuesioner terstruktur, kemudian diolah menjadi fitur numerik untuk membangun model prediksi keberlanjutan usaha (aktif/tidak aktif). Pendekatan ini dipilih karena sesuai dengan tujuan penelitian yang berfokus pada pengukuran hubungan antar variabel dan pembangunan model prediksi berbasis data.

Secara garis besar, metode penelitian terdiri atas beberapa tahapan utama, yaitu: identifikasi masalah dan studi literatur, pengumpulan data, pra-pemrosesan data, Analisa dan Pengolahan Data menggunakan ELM integrasi hasil ke dalam dashboard Power BI, Perancangan Sistem Menggunakan Agile Dev, pengujian dan evaluasi serta penarikan kesimpulan. Alur lengkap proses tersebut digambarkan pada Kerangka Kerja Penelitian pada Gambar 1, yang menghubungkan proses dari akuisisi data hingga visualisasi hasil prediksi.



Gambar 1. Kerangka Kerja Penelitian

Uraian kerangka kerja akan dijelaskan pada bagian dibawah ini:

1. Identifikasi Masalah dan Studi Literatur. Langkah awal penelitian ini dimulai dengan mengidentifikasi permasalahan utama yang dihadapi oleh UMKM, khususnya terkait keberlanjutan usaha di era digital. Kajian literatur dilakukan untuk memahami tren terkini dalam penerapan teknologi kecerdasan buatan dan visualisasi data pada sektor UMKM. Penelitian sebelumnya telah menunjukkan bahwa adopsi teknologi dapat meningkatkan efisiensi, tetapi masih minim dalam hal implementasi prediksi berbasis machine learning pada keberlanjutan UMKM.
2. Pengumpulan Data. Data dikumpulkan dari UMKM di wilayah Sumatera Barat khususnya kota Padang melalui metode survei, wawancara, serta pengumpulan data sekunder dari instansi terkait. Data mencakup variabel finansial, operasional, pemasaran, dan sosial yang berkontribusi terhadap keberlanjutan UMKM.
3. Pra-pemrosesan Data. Data yang terkumpul kemudian melalui beberapa tahap pra-pemrosesan, meliputi Data cleaning untuk menghapus duplikasi, menangani nilai hilang, dan mengeliminasi fitur tanpa variansi. Encoding variabel kategorikal (label encoding untuk variabel ordinal dan one-hot encoding untuk variabel

- nominal). Normalisasi menggunakan *Min–Max Normalization* agar seluruh fitur berada pada rentang 0–1 dan sesuai dengan karakteristik input ELM.
4. Analisa dan Pengolahan Data. Pada tahap ini, ELM digunakan sebagai algoritma utama untuk membangun model prediksi keberlanjutan UMKM. ELM merupakan jaringan saraf dengan satu *hidden layer* yang melakukan penentuan bobot input dan bias secara acak, sementara bobot output dihitung secara analitik menggunakan *pseudo-inverse*, sehingga proses pelatihan menjadi sangat cepat dan efisien. Dataset dibagi menjadi 80% data latih dan 20% data uji. Proses pelatihan diawali dengan pencarian konfigurasi hiperparameter terbaik menggunakan *grid search* terhadap tiga komponen utama: jumlah *neuron hidden* (H), fungsi aktivasi (f), dan koefisien regularisasi L2 (λ). Setiap kombinasi diuji untuk memperoleh model dengan kinerja klasifikasi terbaik. Konfigurasi optimal yang diperoleh kemudian digunakan sebagai arsitektur akhir model ELM yang diringkas dalam tabel ringkasan arsitektur dan ilustrasi arsitektur ELM pada bagian hasil. Visualisasi Dinamis Menggunakan Power BI Hasil prediksi dari model ELM akan divisualisasikan secara dinamis menggunakan Power BI *Dashboard* Power BI akan mengintegrasikan data hasil prediksi dan menampilkan rekomendasi dalam bentuk indikator visual (warna, grafik batang, tren bulanan). Pelatihan singkat juga akan diberikan kepada pelaku UMKM agar dapat memahami tampilan dan interpretasi hasil.
 5. Perancangan Sistem. Perancangan sistem dilakukan untuk memastikan proses integrasi antara model prediksi ELM dan dashboard visualisasi Power BI berjalan secara optimal. Tahapan perancangan meliputi identifikasi kebutuhan pengguna (UMKM dan pemangku kepentingan), alur data dari tahap preprocessing hingga integrasi hasil prediksi, serta desain antarmuka dashboard. Pendekatan *agile development* digunakan untuk memungkinkan pengembangan yang interaktif dan fleksibel.
 6. Pengujian dan Evaluasi. Kinerja model dievaluasi menggunakan data uji melalui metrik akurasi, *precision*, *recall*, dan *F1-score* yang dihitung dari *confusion matrix*. Selain pengujian tunggal, dilakukan pula skema *5-fold cross validation* untuk menilai stabilitas dan kemampuan generalisasi model terhadap variasi subset data. Analisis tambahan dilakukan melalui kurva ROC, kurva *precision–recall*, serta distribusi probabilitas prediksi untuk memahami karakteristik keputusan model secara lebih mendalam.
 7. Hasil dan Kesimpulan. Bagian ini menyajikan ringkasan hasil analisis dari model ELM dan *dashboard Power BI*. Hasil pengujian model menunjukkan tingkat akurasi dan performa klasifikasi dalam memprediksi keberlanjutan UMKM. Selain itu, dashboard interaktif yang dibangun mampu menampilkan indikator penting seperti skor keberlanjutan, tren risiko, dan faktor-faktor dominan yang memengaruhi kondisi usaha. Kesimpulan penelitian menyoroti efektivitas pendekatan integratif antara machine learning dan visualisasi data dalam memberikan wawasan yang lebih dalam bagi UMKM untuk pengambilan keputusan. Temuan penelitian ini diharapkan dapat menjadi dasar untuk pengembangan sistem intelligent decision support yang lebih komprehensif pada skala yang lebih luas.

3. Hasil dan Pembahasan

Pada bagian ini dipaparkan hasil pengolahan data serta performa model ELM dalam memprediksi keberlanjutan UMKM. Analisis dilakukan untuk melihat sejauh mana model mampu mengenali pola pada data, sekaligus bagaimana visualisasi Power BI mendukung interpretasi hasil tersebut.

3.1 Pengumpulan Data

Data dikumpulkan melalui penyebaran kuesioner kepada pelaku UMKM di wilayah Sumatera Barat khususnya kota padang, baik secara daring maupun luring. Kuesioner terdiri dari 45 item pertanyaan yang mencakup indikator pada aspek Keuangan, Inovasi dan digitalisasi, Sumber daya manusia, Dukungan eksternal, Kepemimpinan, Lingkungan, Label keberlanjutan usaha (aktif/tidak aktif)

Selain itu, data sekunder diperoleh dari dokumen pendukung seperti profil usaha, laporan operasional, dan informasi pendukung lain dari instansi terkait. Hasil pertanyaan yang digunakan dalam penelitian ditampilkan pada Tabel 1.

Tabel 1. Data Pertanyaan Kuesioner

No	Kode Pertanyaan	Pertanyaan	Skala
1	Identitas - Q1	Jenis kelamin	1=Pria; 2=Wanita
2	Identitas - Q2	Usia	Isian angka (tahun)
3	Identitas - Q3	Pendidikan terakhir	SD/SMP/SMA/Diploma/S1/S2
4	Identitas - Q4	Lokasi usaha (Kota/Kabupaten)	pilihan
5	Identitas - Q5	Jenis usaha utama	pilihan
...
41	Lingkungan - Q1	Permintaan produk terpengaruh oleh kondisi ekonomi/pandemi	1 Tidak pernah - 5 Selalu
42	Lingkungan - Q2	Usaha memperhatikan dampak lingkungan dari aktivitasnya	1 Tidak pernah - 5 Selalu
43	Lingkungan - Q3	Usaha menjaga hubungan baik dengan masyarakat sekitar	1 Tidak pernah - 5 Selalu
44	Lingkungan - Q4	Usaha menyesuaikan jam operasional dengan kondisi lingkungan	1 Tidak pernah - 5 Selalu
45	Label - Q1	Apakah usaha Anda masih aktif hingga saat ini?	1=Ya; 0=Tidak

Tabel 1 merangkum butir pertanyaan kuesioner yang digunakan dalam penelitian, meliputi kode, isi pertanyaan, dan skala pengukuran untuk setiap indikator keberlanjutan UMKM.

3.2. Pra-pemrosesan Data

Data yang terkumpul selanjutnya diproses agar layak digunakan dalam pemodelan. Tahapan pra-pemrosesan meliputi:

3.2.1 Data Cleaning

Pada tahap *data cleaning*, dilakukan proses pembersihan dan penyesuaian dataset untuk memastikan kualitas dan konsistensi data sebelum digunakan dalam pelatihan model Extreme Learning Machine (ELM). Proses ini meliputi pemeriksaan nilai duplikat, perbaikan format, serta penanganan nilai kosong atau tidak konsisten. Selain itu, kolom “Identitas – Q4” dihapus dari dataset karena seluruh isinya memiliki nilai yang sama, yaitu “Padang”. Kondisi ini menyebabkan kolom tersebut tidak memiliki variansi (variasi nilai) dan tidak memberikan kontribusi informasi terhadap proses pembelajaran model. Secara analitis, fitur yang homogen seperti ini tidak membantu model dalam membedakan antara kategori UMKM yang berkelanjutan dan yang tidak berkelanjutan. Oleh karena itu, penghapusan kolom ini dilakukan untuk meningkatkan efisiensi model serta memastikan hanya fitur yang relevan dan berpengaruh yang digunakan dalam proses prediksi.

3.2.2 Encoding Variabel Data Kategorikal

Variabel kategorikal dalam dataset, seperti “Identitas – Q3” dan “Identitas – Q5”, diubah menjadi format numerik melalui proses *encoding*. Variabel Q3 yang bersifat ordinal dikonversi menggunakan *label encoding* berdasarkan urutan logis antar kategori, sedangkan variabel Q5 yang bersifat nominal ditransformasi menggunakan *one-hot encoding* untuk menghindari bias urutan. Transformasi ini memastikan seluruh fitur dapat diproses oleh model ELM tanpa kehilangan makna semantik dari data aslinya.

3.2.3 Normalisasi Data

Tahapan normalisasi dilakukan terhadap seluruh fitur numerik yang telah melalui proses *cleaning* dan *encoding*. Proses ini bertujuan untuk menyeragamkan skala antar variabel, sehingga setiap fitur memiliki kontribusi yang seimbang dalam proses pembelajaran model *Extreme Learning Machine* (ELM). Metode *Min-Max Normalization* diterapkan dengan mentransformasikan nilai setiap fitur ke dalam rentang 0–1, sesuai persamaan 1.

$$x' = \frac{(x - x_{\{min\}})}{(x_{\{max\}} - x_{\{min\}})} \quad (1)$$

Pendekatan ini dipilih karena sesuai dengan karakteristik model ELM yang sensitif terhadap perbedaan skala input, serta dapat meningkatkan efisiensi komputasi dan stabilitas hasil pelatihan model, dapat dilihat pada tabel 2.

Tabel 2. Normalisasi Data

No	Identitas - Q1	Identitas - Q2	Identitas - Q3	Identitas - Q6	Identitas - Q7	..	Kepemimpinan - Q4	Lingkungan - Q1	Lingkungan - Q2	Lingkungan - Q3	Lingkungan - Q4
1	0.5	0.555	0.333	0.25	0.0625	..	0.75	0.5	0.0	0.75	1.0
2	0.75	0.444	0.999	0.45	0.0	..	0.25	0.75	0.0	1.0	0.5
3	0.75	0.4	0.333	0.65	0.125	..	1.0	0.0	0.25	1.0	0.0
4	0.75	0.311	0.666	0.150	0.0	..	1.0	0.0	1.0	1.0	0.25
5	0.75	0.555	0.0	0.4	0.0	..	0.25	0.25	0.75	1.0	1.0
6	1.0	0.0	0.0	0.4	0.125	..	0.75	1.0	0.75	0.5	0.75
7	1.0	0.466	0.0	0.700	0.0	..	1.0	0.75	0.25	0.75	0.75
8	0.5	0.666	0.0	0.2	0.125	..	0.5	0.5	0.75	1.0	0.75
9	1.0	0.333	0.666	0.600	0.0625	..	0.75	1.0	1.0	0.75	0.75
10	0.5	0.511	0.333	0.300	0.125	..	0.75	1.0	0.75	0.5	1.0
....
490	0.0	0.288	0.333	0.0	0.125	..	0.25	0.25	0.0	0.5	0.0
491	0.5	0.422	0.333	0.5	0.125	..	0.5	0.0	0.25	0.5	0.25
492	0.25	0.488	0.333	0.700	0.0	..	0.75	0.0	0.25	0.0	0.25
493	0.5	0.622	0.666	0.2	0.0625	..	0.75	0.75	0.0	0.5	0.25
494	0.0	0.688	0.333	0.5	0.125	..	0.25	0.25	0.5	0.5	0.0
495	0.25	0.244	0.333	0.0	0.1875	..	0.0	0.75	0.25	0.25	0.25
496	0.0	0.311	0.333	0.4	0.0625	..	0.25	0.25	0.0	0.5	0.5
497	0.0	0.155	0.0	0.0	0.0625	..	0.0	0.25	0.0	1.0	0.25
498	0.25	0.488	0.0	0.5	0.0625	..	0.5	0.5	1.0	0.0	0.5
499	0.0	0.222	0.666	0.65	0.0	..	0.0	0.5	1.0	0.25	0.75
500	0.75	0.222	0.666	0.05	0.125	..	0.0	0.0	0.0	0.0	0.25

Tabel 2 menampilkan contoh hasil normalisasi fitur setelah proses cleaning dan encoding. Seluruh variabel numerik dipetakan ke rentang 0–1 menggunakan *Min–Max Normalization*, sehingga setiap fitur memiliki kontribusi seimbang dalam proses pembelajaran model ELM.

3.2.4 Split Dataset

Setelah proses pra-pemrosesan selesai, Dataset dibagi menjadi 80% data latih (*training set*) dan 20% data uji (*testing set*) untuk mengukur performa generalisasi model seperti pada tabel 3.

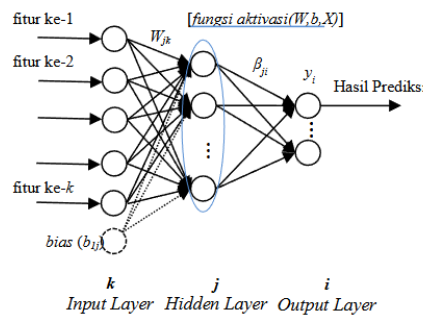
Tabel 3 Split Dataset

Split Data	Training set	Testing set
80% : 20%	400	100

Tabel 3 menunjukkan pembagian dataset menjadi 400 data latih (80%) dan 100 data uji (20%). Proporsi ini digunakan untuk mengukur kemampuan generalisasi model terhadap data yang belum pernah dilihat sebelumnya.

3.3 Analisis dengan *Extreme Learning Machine* (ELM)

Extreme Learning Machine (ELM) digunakan sebagai algoritma utama untuk membangun model prediksi keberlanjutan UMKM. ELM merupakan jaringan saraf tiruan dengan satu hidden layer (*Single Hidden Layer Feedforward Neural Network* / SLFN) yang memiliki karakteristik pelatihan sangat cepat karena bobot input dan bias ditentukan secara acak, sedangkan bobot output dihitung menggunakan solusi analitik menggunakan pseudo-inverse [17]. Secara umum, struktur dasar ELM yang digunakan dalam penelitian ini ditunjukkan pada Gambar 2.



Gambar 2. Arsitektur ELM

Gambar 2 menggambarkan arsitektur umum Extreme Learning Machine yang terdiri atas lapisan input, satu hidden layer, dan lapisan output. Bobot antara lapisan input dan hidden diinisialisasi secara acak, sedangkan bobot dari hidden ke output dihitung melalui solusi analitik berbasis pseudo-inverse.

3.3.1 Proses Data Training

Pada tahap ini, model Extreme Learning Machine (ELM) dilatih menggunakan 400 data training yang telah melalui proses cleaning, encoding, dan normalisasi. Setiap sampel data merepresentasikan satu unit UMKM dengan 44 fitur input hasil pengolahan kuesioner serta satu label keluaran yang menunjukkan status keberlanjutan usaha (1 = usaha masih aktif, 0 = tidak aktif). Nilai bobot input dan bias pada hidden layer ditentukan secara acak sesuai karakteristik ELM, kemudian dihitung keluaran hidden layer dan bobot output menggunakan solusi analitik. Proses pelatihan ini menghasilkan sebuah model awal yang mampu memetakan pola hubungan antara variabel-variabel indikator keberlanjutan dan label kondisi UMKM. Ringkasan Arsitektur ELM pada proses Data Training ini dapat dilihat pada tabel 4 dan gambar 3 dibawah.

Tabel 4. Konfigurasi pengujian grid search

Hiperparameter	Notasi	Nilai yang diuji
Jumlah neuron hidden	H	{100, 200, 300, 500, 800}
Fungsi aktivasi	f	{sigmoid, tanh, ReLU}
Koefisien regularisasi L2 λ		{ 10^{-4} , 10^{-3} , 10^{-2} , 10^{-1} }

Tabel 4 menjelaskan ruang pencarian hiperparameter yang digunakan dalam proses *grid search*. Tiga komponen utama yang diuji adalah jumlah neuron hidden (H), fungsi aktivasi (f), dan koefisien regularisasi L2 (λ), sehingga secara keseluruhan terdapat 60 kombinasi konfigurasi yang dievaluasi.

Tabel 5. Hyperparameter terbaik setelah pengujian grid search

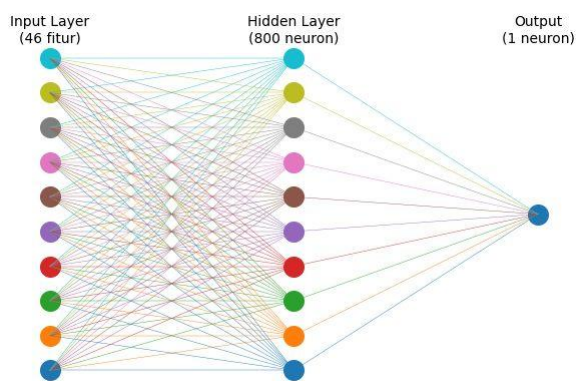
index	n_hidden	activation	l2	acc	prec	rec	f1
56	800	relu	0.0001	0.81	0.7246376811594203	1.0	0.8403361344537815
57	800	relu	0.001	0.81	0.7246376811594203	1.0	0.8403361344537815
58	800	relu	0.01	0.81	0.7246376811594203	1.0	0.8403361344537815
59	800	relu	0.1	0.81	0.7246376811594203	1.0	0.8403361344537815
47	500	relu	0.1	0.79	0.704225352112676	1.0	0.8264462809917356
45	500	relu	0.001	0.78	0.6944444444444444	1.0	0.819672131147541
46	500	relu	0.01	0.78	0.6944444444444444	1.0	0.819672131147541
44	500	relu	0.0001	0.78	0.6944444444444444	1.0	0.819672131147541
32	300	relu	0.0001	0.76	0.6756756756756757	1.0	0.8064516129032258
33	300	relu	0.001	0.76	0.6756756756756757	1.0	0.8064516129032258

Tabel 5 menampilkan beberapa kombinasi hiperparameter terbaik berdasarkan nilai akurasi, precision, recall, dan F1-score. Dari hasil tersebut terlihat bahwa konfigurasi dengan 800 neuron hidden, fungsi aktivasi ReLU, dan regularisasi L2 antara 0,0001 hingga 0,1 memberikan performa tertinggi pada data uji. Berdasarkan hasil grid search pada Tabel 4 dan Tabel 5, diperoleh konfigurasi terbaik yang ringkasannya disajikan pada Tabel 6.

Tabel 6. Ringkasan Arsitektur ELM Data Training

Komponen	Notasi	Nilai / Keterangan
Jumlah sampel latih	(n_{train})	400
Jumlah fitur input	(d)	46 (fitur UMKM)
Jumlah neuron hidden	(H)	800
Fungsi aktivasi	(f)	ReLU
Koefisien regularisasi L2 (λ)		0,0001
Random state	–	42
Struktur layer	–	46–800–1 (input–hidden–output)

Tabel 6 merangkum arsitektur akhir model ELM yang digunakan dalam penelitian, meliputi jumlah sampel latih, jumlah fitur input, jumlah neuron pada hidden layer, fungsi aktivasi, nilai regularisasi L2, random state, serta struktur layer 46–800–1.

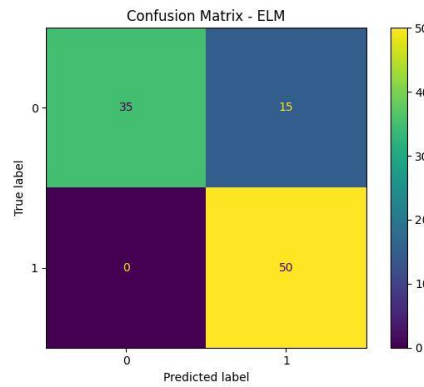


Gambar 3. Arsitektur ELM Data Training

Gambar 3 memberikan representasi visual arsitektur model ELM terpilih dengan 46 neuron pada lapisan input, 800 neuron pada hidden layer, dan satu neuron pada lapisan output yang merepresentasikan kelas keberlanjutan usaha (aktif/tidak aktif).

3.3.2 Uji Model pada Data Testing

Setelah model dilatih, pengujian dilakukan menggunakan 100 data testing yang tidak pernah terlibat dalam proses pelatihan. Tahap ini bertujuan mengukur kemampuan model dalam melakukan generalisasi terhadap data baru dan mengidentifikasi pola prediksi benar maupun salah. Informasi ini selanjutnya digunakan untuk menyusun confusion matrix serta menjadi dasar perhitungan metrik evaluasi kinerja model dapat dilihat pada gambar 4.



Gambar 4. Confusion matrix

Gambar 4 menampilkan confusion matrix hasil prediksi model pada data testing. Dari matriks ini dapat dilihat distribusi true positive, true negative, false positive, dan false negative yang menjadi dasar perhitungan metrik akurasi, precision, recall, dan F1-score.


3.3.3 Evaluasi Model

Tahap ini menyajikan evaluasi lebih lanjut terhadap stabilitas performa model melalui skema cross 5-fold validation dan analisis kurva ROC, precision-recall, serta distribusi probabilitas prediksi.

Tabel 7. ringkasan matrix tanpa cross validation

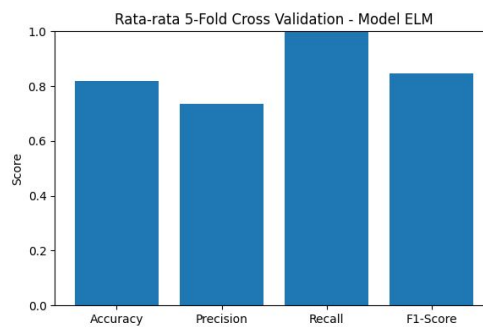
Metrik	Nilai
Akurasi	0.890
Precision	0.820
Recall	1.000
F1-score	0.901

Tabel 7 merangkum nilai akurasi, precision, recall, dan F1-score yang diperoleh model pada data testing tanpa cross validation. Nilai-nilai ini menunjukkan bahwa model mampu mengidentifikasi UMKM berkelanjutan dengan tingkat recall yang sangat tinggi disertai precision dan F1-score yang cukup baik.



Gambar 5. Hasil Cross 5-fold validation

Gambar 5 menampilkan performa model pada setiap fold dalam skema 5-fold cross validation. Pola nilai akurasi dan F1-score yang relatif konsisten antar fold mengindikasikan bahwa model memiliki stabilitas yang baik terhadap variasi subset data latih dan uji.




Gambar 6. barchart Cross 5-fold validation

Gambar 6 menyajikan perbandingan nilai akurasi, precision, recall, dan F1-score rata-rata dalam bentuk diagram batang, sehingga mempermudah interpretasi kontribusi masing-masing metrik terhadap kualitas model secara keseluruhan.

Tabel 8. metrik evaluasi cross 5-fold validation


Metrik	Nilai
Mean Akurasi	0.820
Mean Precision	0.736
Mean Recall	1.000
Mean F1-score	0.847

Tabel 8 merangkum nilai rata-rata akurasi, precision, recall, dan F1-score yang diperoleh dari 5-fold cross validation. Hasil ini menunjukkan bahwa meskipun akurasi dan precision sedikit menurun dibanding pengujian tunggal, nilai recall tetap tinggi sehingga model cenderung tidak melewatkan UMKM yang berpotensi berkelanjutan.



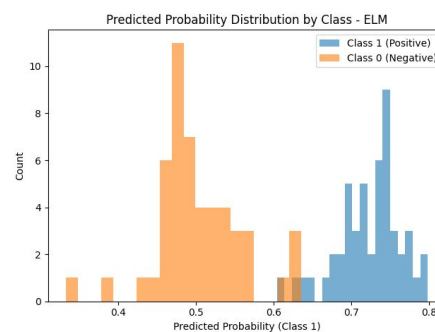
Gambar 7. ROC

Gambar 7 memperlihatkan kurva ROC yang menggambarkan trade-off antara true positive rate dan false positive rate. Area di bawah kurva (AUC) yang tinggi mengindikasikan kemampuan diskriminatif model yang baik dalam membedakan UMKM aktif dan tidak aktif.



Gambar 8. precision recall

Gambar 8 menunjukkan hubungan antara precision dan recall pada berbagai threshold probabilitas. Kurva yang berada di atas baseline mengkonfirmasi bahwa model memberikan keseimbangan yang baik antara ketepatan dan kelengkapan deteksi kelas positif.



Gambar 9. PDD

Gambar 9 menampilkan distribusi probabilitas prediksi keberlanjutan UMKM yang dihasilkan model. Visualisasi ini membantu melihat sebaran keyakinan model, termasuk area yang mendekati batas keputusan (sekitar 0,5) yang berpotensi menjadi kasus ambigu.

3.4 Hasil prediksi

Bagian ini menyajikan output prediksi model ELM pada seluruh data UMKM, baik data latih maupun data uji. Setiap baris data memuat atribut identitas, label aktual, probabilitas keberlanjutan, serta keputusan prediksi model.

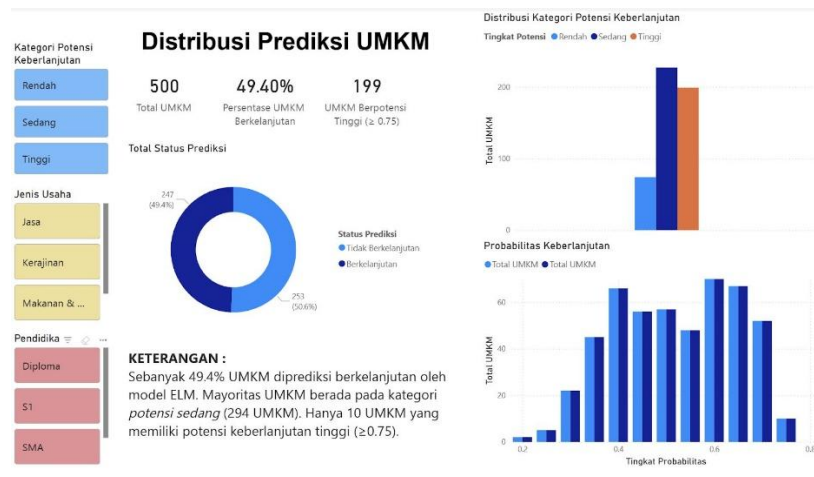
Tabel 9. hasil prediksi pada semua data

No	Identitas - Q1	Identitas - Q2	Identitas - Q3	Identitas - Q4	Identitas - Q5	Identitas - Q6	Identitas - Q7	Identitas - Q8	Label - Q1	Prob_Keberlanjutan	Prediksi Aktif	is_test
1	3	43	SMA	Padang	Fashion	5	2	5	1	0.73105849 88225919	1	0
2	4	38	S1	Padang	Makanan & Minuman	9	1	3	1	0.69247456 0564795	1	1
3	4	36	SMA	Padang	Jasa	13	3	2	1	0.73105855 93218811	1	0
4	4	32	Diploma	Padang	Fashion	3	1	5	1	0.73105847 45804426	1	0
5	4	43	SMK	Padang	Jasa	8	1	4	1	0.73105847 26739572	1	0
6	5	18	SMK	Padang	Ritel	8	3	5	1	0.73105866 27601678	1	0
7	5	39	SMK	Padang	Ritel	14	1	4	1	0.75914707 69292737	1	1
8	3	48	SMK	Padang	Jasa	4	3	5	1	0.73105842 63516647	1	0
9	5	33	Diploma	Padang	Fashion	12	2	5	1	0.69933972 43133816	1	1
10	3	41	SMA	Padang	Ritel	6	3	4	1	0.73105846 24026003	1	0
.....
490	1	31	SMA	Padang	Ritel	0	3	1	0	0.46003819 9047159	0	1
491	3	37	SMA	Padang	Makanan & Minuman	10	3	1	0	0.50000029 62965289	0	0
492	2	40	SMA	Padang	Jasa	14	1	3	0	0.50000003 23501275	0	0
493	3	46	Diploma	Padang	Ritel	4	2	1	0	0.48380400 57402478	0	1
494	1	49	SMA	Padang	Makanan & Minuman	10	3	4	0	0.49999998 04476737	0	0
495	2	29	SMA	Padang	Fashion	0	4	2	0	0.49999991 67352899	0	0
496	1	32	SMA	Padang	Fashion	8	2	2	0	0.50000002 89658517	0	0
497	1	25	SMK	Padang	Fashion	0	2	3	0	0.51495144 16819845	0	1
498	2	40	SMK	Padang	Ritel	10	2	2	0	0.49999999 24849531	0	0
499	1	28	Diploma	Padang	Makanan & Minuman	13	1	1	0	0.49999998 717756233	0	0
500	4	28	Diploma	Padang	Makanan & Minuman	1	3	1	0	0.50261500 60391725	0	1

Tabel 9 memperlihatkan hasil prediksi yang dihasilkan model, termasuk nilai probabilitas keberlanjutan dan label prediksi untuk masing-masing UMKM. Informasi ini dapat digunakan untuk mengidentifikasi usaha yang berisiko tidak berkelanjutan maupun yang memiliki potensi tinggi untuk terus bertahan.

3.5 Visualisasi Dinamis Menggunakan Power BI

ini menjelaskan integrasi hasil prediksi ELM ke dalam dashboard interaktif Power BI. Dashboard dirancang agar pelaku UMKM dan pemangku kepentingan dapat memantau skor keberlanjutan, tren risiko, serta faktor dominan yang memengaruhi kondisi usaha secara intuitif dapat dilihat pada gambar dibawah.



Gambar 10. Visualisasi dashboard interaktif power BI

Gambar 10 menampilkan tampilan dashboard Power BI yang menyajikan ringkasan skor keberlanjutan UMKM, distribusi kategori risiko, serta grafik tren dan filter interaktif. Pengguna dapat melakukan eksplorasi data secara dinamis untuk mendukung proses pengambilan keputusan berbasis data.

4. Kesimpulan

Penelitian ini berhasil membangun model prediksi keberlanjutan UMKM menggunakan algoritma Extreme Learning Machine (ELM) berbasis data kuesioner sebanyak 500 responden, dengan 400 data digunakan sebagai data latih dan 100 data sebagai data uji. Model terbaik menggunakan 46 fitur input, 800 neuron pada hidden layer, fungsi aktivasi ReLU, serta regularisasi L2 sebesar 0,0001.

Hasil pengujian pada data testing menunjukkan bahwa model ELM mampu memberikan kinerja klasifikasi yang sangat baik dengan akurasi 0,890, precision 0,820, recall 1,000, dan F1-score 0,901. Sementara itu, skema evaluasi cross 5-fold validation menghasilkan rerata akurasi 0,820, precision 0,736, recall 1,000, dan F1-score 0,847. Temuan ini menunjukkan bahwa model relatif stabil dan memiliki kemampuan generalisasi yang baik, dengan kecenderungan meminimalkan kesalahan dalam mengidentifikasi UMKM yang masih aktif.

Integrasi hasil prediksi ke dalam dashboard interaktif Power BI memungkinkan penyajian informasi keberlanjutan UMKM secara lebih intuitif, seperti skor probabilitas keberlanjutan, distribusi kategori risiko, serta profil masing-masing pelaku usaha. Visualisasi dinamis ini berpotensi mendukung pengambilan keputusan berbasis data bagi pelaku UMKM maupun pemangku kepentingan dalam merancang intervensi dan strategi pendampingan yang lebih tepat sasaran. Ke depan, penelitian ini dapat dikembangkan dengan menambah jumlah dan keragaman sampel di luar Kota Padang, melakukan eksplorasi fitur tambahan (misalnya data transaksi riil atau perilaku digital), membandingkan ELM dengan algoritma pembelajaran mesin lainnya, serta mengintegrasikan dashboard dengan data yang diperbarui secara berkala agar sistem prediksi keberlanjutan UMKM menjadi lebih adaptif.

Ucapan Terimakasih

Peneliti mengucapkan terimakasih kepada Kemendikti Sainstek sebagai pemberi dana penelitian pada program penerimaan proposal penelitian dan pengabdian kepada masyarakat hibah DRTPM 2025. Sehingga penelitian ini bisa dilaksanakan hingga selesai dengan nomor kontrak induk DPPM-LLDIKTI X sebagai berikut, 131/C3/DT.05.00/PL/2025 yang dikeluarkan tanggal 28 Mei 2025, dan nomor kontrak turunan LLDIKTI X- Univ Adzkie 013/LL10/DT.05.00/PL/2025 yang dikeluarkan tanggal 2 Juni 2025, serta kontrak turunan LPPM-Peneliti 010.3/LPPMPenelitian/UA/2025 dikeluarkan tanggal 4 Juni 2025.

Daftar Rujukan

- [1] M. A. Fathoni and A. A. Bhrata, "Smart Manufacturing Management System Memanfaatkan Big Data Dan Algoritma Machine Learning Untuk Produksi Umkm," *J. Sci. Innov. Technol.*, vol. 3, no. 1, pp. 36–47, 2023, doi: 10.47701/sintech.v3i1.2523.
- [2] Aisah, S. N., Dian Candra Rini Novitasari, & Farida, Y. . (2023). Perbandingan Metode Extreme Learning Machine (ELM) dan Kernel Extreme Learning Machine (KELM) Pada Klasifikasi Penyakit Cedera Panggul . *Jurnal Fourier*, 12(2), 69–78. <https://doi.org/10.14421/fourier.2023.122.69-78>
- [3] S. Aisyah, N. Ulinnuha, and A. Hamid, "Penerapan Extreme Learning Machine Dalam Meramalkan Harga Minyak Sawit Mentah," *KUBIK J. Publ. Ilm. Mat.*, vol. 7, no. 2, pp. 97–105, 2023, doi: 10.15575/kubik.v7i2.20460.
- [4] I. B. K. Purnama, Annas; Wijaya, I Nyoman Yudi Anggara; Sudiatmika, "2030-Article Text-5437-1-10-20220915," *Penerapan Bus. Intel. Untuk Menganalisis Data Penjualan Menggunakan Power Bi*, vol. 4, no. 2, pp. 118–123, 2022.

- [5] E. Purnamasari and D. A. Verano, "Model Data-Driven untuk Prediksi Digitalisasi UMKM Menggunakan GMM dan XGBoost," *J. Pustaka AI* ..., vol. 5, no. 2, pp. 204–214, 2025, [Online]. Available: <https://mail.pustakagalerimandiri.co.id/jurnalpgm/index.php/pustakaai/article/view/984%0Ahttps://mail.pustakagalerimandiri.co.id/jurnalpgm/index.php/pustakaai/article/download/984/779>
- [6] B. Lailatul Nafiisa, Y. Novealita Wahono Putri, and Q. Ayunin, "Dashboard Visualisasi Data UMK Sebagai Alat Pengambilan Keputusan Menggunakan Microsoft Power BI," *Akunt. dan Manaj.*, vol. 17, no. 2, pp. 86–105, 2022, [Online]. Available: <https://akuntansi.pnp.ac.id/jam>
- [7] G. A. Prastian, A. Setiawan, and N. K. Bachtar, "SMEs' Sustainability: Between Business Resilience and Business Growth, Which One is More Significant in The Time of Crisis?," *J. Manaj. Bisnis*, vol. 9, no. 1, pp. 94–105, 2022, doi: 10.33096/jmb.v9i1.69.
- [8] Terttiaavini, "Prediksi Keberlanjutan Usaha Kecil Menengah (UKM) Menggunakan Algoritma Machine Learning Article Info ABSTRAK," *JSAI J. Sci. Appl. Informatics*, vol. 8, no. 1, pp. 29–37, 2025.
- [9] Abdillah Baradja, Sukoco, and Tri Irianto Tjendrowasono, "Penerapan Machine Learning untuk Meningkatkan Prediksi Mata Uang Forex dengan Indikator Teknikal," *J. Pus. Akses Kaji. Teknol. Artif. Intell.*, vol. 2, no. 1, pp. 38–41, 2023.
- [10] F. G. Sinuhaji, H. J. Sibarani, and V. M. Pakpahan, "MSMEs and the Role of Technology in Achieving Business Sustainability," *J. Artif. Intell. Eng. Appl.*, vol. 4, no. 1, 2024, doi: 10.59934/jaiea.v4i1.724.
- [11] Sugiyono, *Metodologi Penelitian Kuantitatif, Kualitatif dan R & D*. 2020.
- [12] E. Alshdaifat, D. Alshdaifat, A. Alsarhan, F. Hussein, and S. M. F. S. El-Salhi, "The effect of preprocessing techniques, applied to numeric features, on classification algorithms' performance," *Data*, vol. 6, no. 2, pp. 1–23, 2021, doi: 10.3390/data6020011.
- [13] M. H. Qasem and L. Nemer, "Extreme Learning Machine for Credit Risk Analysis," *J. Intell. Syst.*, vol. 29, no. 1, pp. 640–652, 2020, doi: 10.1515/jisys-2018-0058.
- [14] A. P. Ariyanti, Mazdadi, M. I., Muliadi, M., & Herteno, R. (2023). Application of Extreme Learning Machine Method With Particle Swarm Optimization to Classify of Heart Disease. *IJCCS (Indonesian Journal of Computing and Cybernetics Systems)*, 17(3), 281-290. doi.org/10.22146/ijccs.86291
- [15] K. Nisa Az-Zahra, S. Kautsar, Z. Wardhany, A. Bakhrun, S. Salsabila, and S. Maheswari, "Sales Data Visualization Using Power BI to Support Business Insight and Decision Making in FMCG Industry," *Soc. Econ. Technol.*, vol. 6, no. 1, pp. 613–621, 2025, [Online]. Available: <https://doi.org/10.33122/ejeset.v6i1.646>
- [16] M. Frizky Feri Setiawan and Yekti Condro Winursito, "Operational Data Analysis and Visualization of PT XYZ Using Business Intelligence Approach with Microsoft Power BI," *J. Artif. Intell. Eng. Appl.*, vol. 4, no. 2, pp. 648–653, 2025, doi: 10.59934/jaiea.v4i2.722.
- [17] K. T. P. Marpaung, A. Rusgiyono, and Y. Wilandari, "PERBANDINGAN METODE HOLT WINTER'S EXPONENTIAL SMOOTHING DAN EXTREME LEARNING MACHINE UNTUK PERAMALAN JUMLAH BARANG YANG DIMUAT PADA PENERBANGAN DOMESTIK DI BANDARA UTAMA SOEKARNO HATTA," *Jurnal Gaussian*, vol. 11, no. 3, pp. 439-446, Jan. 2023. doi.org/10.14710/j.gauss.11.3.439-446
