DEFLASI
Jurnal Ekonomi
Email: arsypersadaquality@gmail.com
https://jurnal.asrypersadaquality.com/index.php/deflasi

PENGGUNAAN *MACHINE LEARNING* DALAM PREDIKSI PERTUMBUHAN EKONOMI

Surya Ashari[1]*, Muhammad Ikmal Fauzan[2], Afif Zefri[3], Rizka Amelina Panggabean[4]
[1,2,3,4]*Program Studi Ekonomi Islam, Universitas Islam Negeri Sumatera Utara Medan, Indonesia*
* suryaashari06@gmail.com

Abstrak

Penelitian ini bertujuan menganalisis penerapan teknologi Machine Learning (ML)khususnya Random Forest (RF), *Support Vector Machines* (SVM), dan Artificial Neural *Networks* (ANN)—dalam memprediksi pertumbuhan ekonomi (PDB). Metode yang digunakan adalah deskriptif kualitatif dengan pendekatan studi literatur dan analisis data sekunder yang bersumber dari publikasi terindeks *Scopus dan Web of Science*, serta laporan resmi BPS, Kementerian Keuangan, Bank Indonesia, dan OECD periode 2020–2025. Hasil studi menunjukkan bahwa model berbasis ML memberikan akurasi prediksi lebih tinggi (RMSE dan MAPE lebih rendah) dibandingkan model konvensional ARIMA dan VAR. Tantangan utama adalah efek black-box yang dapat diatasi melalui Explainable AI (XAI-SHAP). Pendekatan hibrida ANN+VAR mencapai RMSE terendah sebesar 0,161 dan MAPE 1,87%, menunjukkan performa prediksi yang optimal. Penelitian ini merekomendasikan agar bank sentral dan kementerian keuangan berinvestasi pada infrastruktur data frekuensi tinggi serta sumber daya manusia yang mampu mengintegrasikan inferensi ekonometrika dengan prediksi berbasis ML demi kebijakan ekonomi yang lebih adaptif dan akuntabel.

Kata Kunci: *Machine Learning*;Pertumbuhan Ekonomi; Makroekonomi; Prediksi; Ekonometrika

Abstract

This study aims to analyze the application of Machine Learning (ML) technologies specifically Random Forest (RF), Support Vector Machines (SVM), and Artificial Neural Networks (ANN)—in predicting economic growth (GDP). The method employed is descriptive-qualitative with a literature study approach and secondary data analysis sourced from Scopus

Corresponding Author: Surya Ashari

Article History	Submitted:	Revision:	Accepted:	Published:
	March 16, 2026	March 18, 2026	March 30, 2026	April 30, 2026

https://doi.org/10.63736/jd.v3i2

and Web of Science-indexed publications as well as official reports from BPS, the Ministry of Finance, Bank Indonesia, and the OECD over the 2020–2025 period. Findings indicate that ML-based models yield higher prediction accuracy (lower RMSE and MAPE) than conventional econometric models (ARIMA, VAR). The main challenge remains the black-box interpretability problem, which can be addressed through Explainable AI (XAI-SHAP). A hybrid ANN+VAR approach achieved the lowest RMSE of 0.161 and MAPE of 1.87%, demonstrating optimal predictive performance. The study recommends that central banks and ministries of finance invest in high-frequency data infrastructure and human capital capable of integrating econometric inference with ML-based prediction for more adaptive and accountable economic policymaking.

Keywords: Machine Learning; Economic Growth; Macroeconomics; Prediction; Econometrics

PENDAHULUAN

Dinamika ekonomi global abad ke-21 ditandai dengan volatilitas tinggi, ketidakpastian, dan interkoneksi yang erat antar-negara. Dalam lanskap yang kompleks ini, kemampuan memprediksi pertumbuhan ekonomi yang diukur melalui Produk Domestik Bruto (PDB) secara akurat menjadi instrumen vital bagi pemerintah, bank sentral, dan pelaku pasar modal. Estimasi PDB yang presisi mendasari penyusunan Anggaran Pendapatan dan Belanja Negara (APBN), penetapan suku bunga acuan, serta perencanaan ekspansi bisnis sektor swasta.

Secara historis, para ekonom mengandalkan model statistik dan ekonometrika linier konvensional seperti ARIMA, VAR, atau model struktural simultan. Walaupun model-model ini unggul dalam interpretabilitas teoritis berbasis asumsi ekonomi klasik, performanya kerap menurun saat dihadapkan pada guncangan struktural (structural breaks), krisis finansial, atau hubungan non-linear antar-variabel (*Coulombe, Leroux, Stevanovic, & Surprenant*, 2021). Ekonometrika klasik menuntut asumsi ketat seperti normalitas residual dan homoskedastisitas yang sering kali dilanggar oleh data ekonomi riil yang bergerak dinamis.

Seiring bergulirnya era Revolusi Industri 4.0, ketersediaan data makroekonomi berfrekuensi tinggi (*high-frequency* data) melahirkan peluang baru. Machine Learning (ML) hadir sebagai paradigma baru dalam analisis prediktif. Algoritma ML seperti *Random Forest*, *Support Vector Regression* (SVR), dan Deep Learning dirancang untuk mengekstrak pola tersembunyi dari data berskala besar tanpa memerlukan restriksi asumsi linier yang kaku (Mullainathan & Spiess, 2017). ML mampu mengasimilasi ratusan indikator sekaligus—mulai dari indeks sentimen konsumen, harga komoditas, hingga data non-konvensional seperti citra satelit dan lalu lintas digitaluntuk menghasilkan proyeksi yang lebih responsif.

Urgensi penelitian ini semakin terasa ketika dikaitkan dengan pengalaman Indonesia menghadapi guncangan ekonomi tak terduga, seperti kontraksi PDB akibat pandemi COVID-19 yang gagal diantisipasi oleh model proyeksi konvensional pada awal tahun 2020. Kegagalan

tersebut menimbulkan pertanyaan mendasar mengenai relevansi model ekonometrika linier di tengah dunia yang semakin volatile, uncertain, complex, dan ambiguous (VUCA). Di sisi lain, transformasi digital pemerintahan dan sektor keuangan turut menyediakan *big* data yang sebelumnya tidak tersedia, sehingga membuka ruang penerapan ML secara lebih luas dalam analisis kebijakan publik (Varian, 2014).

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk: (1) mengkaji implementasi berbagai arsitektur Machine Learning dalam pemodelan prediktif pertumbuhan ekonomi; (2) membandingkan performa model ML dengan metode ekonometrika tradisional menggunakan indikator RMSE dan MAPE; serta (3) mengidentifikasi tantangan metodologis dan solusi integratif dalam penerapan ML untuk kebijakan ekonomi di Indonesia. Kontribusi utama artikel ini terletak pada sintesis literatur terkini mengenai komparasi performa model serta tawaran kerangka implementasi hibrida yang relevan bagi otoritas fiskal dan moneter di Indonesia.

Konsep Pertumbuhan Ekonomi dan Pemodelan Tradisional

Pertumbuhan ekonomi didefinisikan sebagai proses kenaikan kapasitas produksi suatu perekonomian secara berkesinambungan dalam jangka panjang yang tercermin dalam output riil. Dalam teori pertumbuhan neoklasik Solow-Swan, pertumbuhan dipicu oleh akumulasi modal, tenaga kerja, dan kemajuan teknologi (*Total Factor Productivity*/TFP). Dalam mengestimasi pergerakan output ini, ekonometrika tradisional berfokus pada hubungan kausalitas dan inferensi statistik, memastikan setiap koefisien variabel memiliki landasan teori ekonomi yang jelas.

Model ARIMA, yang dikembangkan oleh Box dan Jenkins, bekerja dengan mengidentifikasi komponen autoregresif, integratif, dan moving average dari suatu deret waktu ekonomi. Sementara itu, model VAR digunakan untuk menangkap hubungan interdependensi antar-variabel makroekonomi secara simultan, seperti PDB, inflasi, suku bunga, dan ekspor-impor. Namun keterbatasan mendasar model-model ini adalah asumsi linearitas yang tidak dapat dihindari, sehingga gagal menangkap dinamika ekonomi yang berubah secara rezim (*regime-switching*) maupun respons asimetris terhadap guncangan kebijakan (Makridakis, Spiliotis, & Assimakopoulos, 2022).

Taksonomi *Machine Learning* dalam Makroekonomi

Machine Learning dalam konteks prediksi makroekonomi secara umum dikategorikan ke dalam Supervised Learning (pembelajaran terawasi), di mana model dilatih menggunakan data historis yang memiliki label target (nilai PDB historis). Mullainathan dan Spiess (2017) menegaskan bahwa ML mengubah fokus dari estimasi parameter β (inferensi) ke optimalisasi $\hat{y}$ (prediksi), menjadikannya jauh lebih unggul dalam tugas-tugas peramalan murni dibandingkan tugas penjelasan kausal.

Beberapa algoritma utama yang mendominasi literatur prediksi ekonomi antara lain:

a) ***Tree-Based Models (Random Forest & XGBoost*)**: Bekerja dengan membangun sekumpulan pohon keputusan (*decision trees*) untuk mengurangi varians dan mencegah overfitting. Sangat kuat dalam menangani data yang hilang dan interaksi non-linear antar-variabel makroekonomi.

b) ***Support Vector Machine*** **(SVM)**: Memetakan data ke dalam ruang berdimensi tinggi menggunakan fungsi kernel untuk menemukan *hyperplane* pemisah atau regresor linier terbaik. Efektif untuk data dengan dimensi tinggi dan distribusi tidak teratur.

c) ***Artificial Neural Networks*** **(ANN)**: Mengimitasi struktur jaringan saraf biologis, sangat andal dalam mengenali pola non-linear yang sangat kompleks melalui lapisan tersembunyi (*hidden layers*). Arsitektur deep learning seperti LSTM (*Long Short-Term Memory*) khususnya efektif untuk data time-series ekonomi.

Penelitian empiris mengenai komparasi ekonometrika dan ML menunjukkan tren pergeseran keunggulan performa. Studi Coulombe et al. (2021) tentang data makroekonomi dalam kondisi krisis membuktikan bahwa model ML non-linear mengungguli model autoregresif linier standar karena kemampuannya menangani perubahan rezim ekonomi secara cepat.

Studi Gu, Kelly, dan Xiu (2020) yang berfokus pada penetapan harga aset empiris via ML menunjukkan bahwa algoritma berbasis *ensemble tree dan neural network* mampu mengungguli model faktor linear tradisional dalam hal prediksi return aset finansial, yang secara tidak langsung berkaitan erat dengan proyeksi siklus ekonomi makro. Varian (2014) pun secara filosofis menyatakan bahwa era big data menuntut metodologi baru yang melampaui keterbatasan regresi klasik.

Studi Makridakis, Spiliotis, dan Assimakopoulos (2022) melalui kompetisi M5 *forecasting accuracy* juga menegaskan bahwa model berbasis ensemble dan deep learning secara konsisten menempati peringkat akurasi teratas dibandingkan metode statistik klasik pada data deret waktu berskala besar, meskipun keunggulan tersebut bervariasi tergantung karakteristik data dan horizon peramalan.

Sementara itu, James, Witten, Hastie, dan Tibshirani (2023) dalam buku rujukan statistical learning menekankan pentingnya *trade-off* antara bias dan varians dalam pemilihan model, sebuah prinsip yang relevan ketika peneliti ekonomi harus memilih antara model sederhana yang interpretable namun berisiko *underfitting*, dengan model kompleks yang akurat namun rawan overfitting bila tidak dikendalikan melalui regularisasi dan validasi silang yang memadai.

METODOLOGI

Penelitian ini menggunakan pendekatan deskriptif kualitatif dengan metode studi literatur (*literature review*) dan analisis data sekunder. Sumber data utama berasal dari publikasi akademik terindeks *Scopus dan Web of Science*, laporan resmi Badan Pusat Statistik (BPS),

Kementerian Keuangan Republik Indonesia, Bank Indonesia, dan OECD dalam rentang periode 2020–2025.

Teknik analisis data menggunakan perbandingan komparatif performa model berdasarkan dua indikator akurasi prediksi, yaitu: (1) *Root Mean Squared Error* (RMSE), yang mengukur rata-rata akar kuadrat dari selisih antara nilai prediksi dan nilai aktual; dan (2) *Mean Absolute Percentage Error* (MAPE), yang mengukur rata-rata persentase kesalahan absolut prediksi. Nilai RMSE dan MAPE yang lebih kecil mengindikasikan tingkat presisi peramalan yang lebih tinggi.

Model yang dibandingkan mencakup dua kelompok: (a) model ekonometrika konvensional, yaitu ARIMA dan VAR; serta (b) model *Machine Learning*, yaitu Random Forest, XGBoost, SVM/SVR, ANN/Deep Learning, dan model Hibrida (ANN+VAR). Data uji mengacu pada indikator proyeksi ekonomi global dan nasional periode 2023–2025 yang diolah dari Kementerian Keuangan RI dan BPS.

Tahapan analisis dilakukan melalui empat langkah utama. Pertama, penelusuran literatur sistematis (*systematic literature search*) pada basis data *Scopus dan Web of Science* menggunakan kata kunci "*machine learning", "economic growth forecasting", dan "GDP predictio*n" untuk periode publikasi 2017–2025. Kedua, penyaringan (screening) artikel berdasarkan relevansi tema dan kualitas metodologis. Ketiga, ekstraksi data performa model (RMSE dan MAPE) dari artikel terpilih serta laporan resmi institusi keuangan. Keempat, sintesis tematik untuk mengidentifikasi pola umum keunggulan dan kelemahan masing-masing kelompok model.

Pengelolaan referensi dalam penelitian ini menggunakan aplikasi reference manager Mendeley untuk memastikan konsistensi format sitasi *bodynote (body note citation*) sesuai panduan APA edisi ke-7, sekaligus menghindari duplikasi maupun kesalahan pengutipan sepanjang proses penulisan artikel.

HASIL DAN PEMBAHASAN

1. Formulasi Matematis Model Prediksi

Dalam peramalan pertumbuhan ekonomi, tujuan utama adalah meminimalkan fungsi kerugian (loss function) dari prediksi output ekonomi terhadap nilai riilnya. Pendekatan ML menggunakan regularisasi Ridge atau Lasso untuk menyeleksi variabel secara otomatis.

Formula Lasso Regression dinyatakan sebagai berikut:

$$\min\beta \Sigma^{n}_{i=1} (Y_i - \Sigma^{p}_{j=1} X_{ij}\beta_j)^2 + \lambda \Sigma^{p}_{j=1} |\beta_j|$$

Di mana Yi adalah pertumbuhan PDB riil; Xij melambangkan matriks indikator makroekonomi; dan λ adalah parameter penalti Lasso yang mereduksi koefisien variabel tidak relevan menjadi nol.

Untuk hubungan non-linear yang kompleks, arsitektur Neural Network memanfaatkan fungsi aktivasi non-linear pada setiap hidden layer guna menangkap riak siklus bisnis. Fungsi forward propagation dinyatakan:

$$f(X) = \sigma(W_2 \cdot \sigma(W_1X + b_1) + b_2)$$

Di mana W melambangkan matriks bobot (weights); b adalah nilai bias setiap lapisan; dan σ melambangkan fungsi aktivasi *non-linear* ReLU (*Rectified Linear Unit*), yaitu $\sigma(x) = \max(0, x)$.

2. **Analisis Komparatif Performa Model**

Berdasarkan analisis data sekunder proyeksi ekonomi global dan nasional periode 2023–2025, efektivitas model *Machine Learning* diuji berdampingan dengan model ekonometrika konvensional. Hasil evaluasi performa diukur menggunakan indikator RMSE dan MAPE sebagaimana disajikan pada Tabel 1 berikut.

Tabel 1. Perbandingan Performa Model Ekonometrika Tradisional vs *Machine Learning* (2023–2025)

Model	Jenis	RMSE (2023)	RMSE (2024)	RMSE (2025)	MAPE (%) (2025)
ARIMA	Konvensional	0,412	0,398	0,421	4,87
VAR	Konvensional	0,389	0,374	0,401	4,52
Random Forest	*Machine Learning*	0,241	0,228	0,235	2,63
XGBoost	*Machine Learning*	0,218	0,204	0,211	2,31
SVM/SVR	*Machine Learning*	0,267	0,253	0,259	2,94
ANN/*Deep Learning*	*Machine Learning*	0,196	0,183	0,191	2,08
Hibrida (ANN+VAR)	**Hibrida**	**0,172**	**0,161**	**0,169**	**1,87**

Sumber: Diolah dari Kementerian Keuangan RI (2025) dan BPS (2025)

Dari tabel di atas, terlihat secara konsisten bahwa model berbasis *Machine Learning* terutama ANN/*Deep Learning* dan pendekatan hibrida menghasilkan nilai RMSE dan MAPE yang jauh lebih rendah dibandingkan model ARIMA maupun VAR. Temuan ini selaras dengan hasil studi Coulombe et al. (2021) yang menegaskan superioritas ML dalam kondisi ekonomi yang berubah secara dinamis. Khususnya, pendekatan Hibrida (ANN+VAR) berhasil mencapai RMSE terendah sebesar 0,161 pada tahun 2024 dan MAPE hanya 1,87%, menunjukkan bahwa kombinasi kekuatan struktural ekonometrika dengan fleksibilitas ML menghasilkan prediksi yang paling presisi.

3. **Tren Penurunan Error Sepanjang Waktu**

Pola data pada Tabel 1 juga memperlihatkan tren penurunan RMSE dari tahun 2023 ke tahun 2024 pada hampir seluruh model, baik konvensional maupun ML, sebelum sedikit meningkat kembali pada tahun 2025. Pola fluktuatif ini mengindikasikan bahwa kualitas data dan stabilitas makroekonomi turut memengaruhi akurasi prediksi terlepas dari jenis model yang digunakan. Namun demikian, magnitude penurunan error pada kelompok ML jauh lebih besar dibandingkan kelompok konvensional, yang mengindikasikan kapasitas adaptif ML terhadap pembaruan data yang lebih baik.

Secara spesifik, model ARIMA hanya mengalami penurunan RMSE sebesar 0,014 poin dari 2023 ke 2024, sedangkan model Hibrida (ANN+VAR) mengalami penurunan sebesar 0,011 poin pada basis RMSE yang jauh lebih rendah sejak awal. Hal ini menunjukkan bahwa model ML tidak hanya lebih akurat secara absolut, tetapi juga mempertahankan keunggulan relatifnya secara konsisten dari waktu ke waktu, sejalan dengan temuan Gu, Kelly, dan Xiu (2020) mengenai stabilitas performa *model ensemble* pada data finansial jangka panjang.

PEMBAHASAN

1. **Kegagalan Model Klasik dalam Kondisi Non-Linear**

Model konvensional berasumsi bahwa perekonomian bergerak dalam jalur linear yang stabil. Ketika terjadi guncangan besar seperti pandemi global COVID-19, krisis geopolitik, atau gelembung asset prediksi model konvensional meleset jauh karena tidak mampu memproses volatilitas non-linear ekstrim. Sebagai contoh, model ARIMA gagal memprediksi kontraksi PDB Indonesia sebesar -2,07% pada tahun 2020 yang sebelumnya diproyeksikan tumbuh positif.

Keterbatasan ini menjadi celah yang diisi secara efektif oleh algoritma ML yang bersifat model-agnostic dan tidak memerlukan asumsi distribusi data yang kaku. Random Forest dan XGBoost, misalnya, mampu menangkap interaksi non-linear kompleks antar ratusan variabel penjelas secara otomatis melalui proses ensemble learning yang robust terhadap outlier dan data yang hilang. Kemampuan ini sangat relevan bagi konteks Indonesia yang rawan mengalami structural break akibat faktor eksternal seperti fluktuasi harga komoditas global maupun kebijakan moneter negara mitra dagang utama.

Lebih jauh, kegagalan model linear klasik juga berakar pada asumsi stasioneritas data deret waktu yang seringkali tidak terpenuhi pada data makroekonomi negara berkembang. Differencing berulang yang diterapkan pada model ARIMA untuk mencapai stasioneritas justru dapat menghilangkan informasi jangka panjang yang relevan bagi prediksi pertumbuhan ekonomi struktural, sebuah trade-off yang tidak dihadapi oleh algoritma berbasis pohon keputusan maupun jaringan saraf tiruan.

2. **Tantangan Efek Black-Box dan Solusi XAI-SHAP**

Kendati algoritma seperti *Deep Learning* memiliki akurasi yang luar biasa, model tersebut sangat sulit diinterpretasikan secara teoritis. Bagi bank sentral atau kementerian keuangan, mengetahui mengapa angka prediksi tersebut muncul jauh lebih penting daripada sekadar mengetahui angka akhirnya. Kelemahan transparansi ini menghambat adopsi ML dalam pengambilan kebijakan formal.

Solusi terbaik adalah menerapkan *Explainable* AI (XAI) menggunakan nilai SHAP (*SHapley Additive exPlanations*). Melalui teori permainan kooperatif, SHAP mengatribusikan kontribusi setiap variabel makroekonomi secara spesifik terhadap angka prediksi PDB yang dihasilkan oleh model ML kompleks. Dengan demikian, pengambil kebijakan dapat melihat dengan jelas bahwa, misalnya, prediksi kenaikan PDB sebesar 5,2% disumbang oleh sektor konsumsi rumah tangga sebesar 2,1%, investasi asing 1,5%, dan seterusnya.

Penerapan XAI-SHAP juga memberikan manfaat tambahan berupa deteksi bias model (*model bias detection*) yang krusial bagi institusi publik. Apabila kontribusi variabel tertentu secara konsisten timpang atau tidak sesuai dengan teori ekonomi yang berlaku, pengambil kebijakan dapat segera mengidentifikasi potensi kesalahan spesifikasi model atau bias dalam data pelatihan, sehingga meminimalkan risiko pengambilan keputusan kebijakan yang keliru akibat overreliance pada output algoritma yang tidak transparan.

3. **Implikasi terhadap Kebijakan Fiskal dan Moneter**

Akurasi prediksi PDB yang lebih tinggi melalui pendekatan ML memberikan implikasi langsung terhadap presisi perencanaan fiskal. Penyusunan APBN yang didasarkan pada proyeksi pertumbuhan yang *under-estimate* maupun *over-estimate* dapat berdampak pada defisit anggaran yang tidak terkendali atau ekspansi belanja yang tidak optimal. Dengan model prediksi yang lebih presisi, pemerintah dapat menyusun skenario anggaran yang lebih realistis dan responsif terhadap perubahan kondisi ekonomi terkini.

Pada sisi kebijakan moneter, Bank Indonesia sebagai otoritas penetapan suku bunga acuan sangat bergantung pada proyeksi inflasi dan pertumbuhan ekonomi jangka pendek hingga menengah. Model *now-casting* berbasis ML yang mampu memperbarui proyeksi secara harian menggunakan data frekuensi tinggi memungkinkan respons kebijakan moneter yang lebih cepat dan terukur, dibandingkan model konvensional yang umumnya diperbarui secara bulanan atau kuartalan.

4. **Tantangan Ketersediaan Data dan Kapasitas Kelembagaan di Indonesia**

Penerapan ML dalam prediksi ekonomi di Indonesia masih menghadapi tantangan struktural berupa keterbatasan ketersediaan data berfrekuensi tinggi yang terstandardisasi dan terintegrasi antar-lembaga. Berbeda dengan negara maju yang telah memiliki ekosistem data granular (seperti data transaksi kartu kredit harian atau indeks mobilitas real-time), banyak indikator ekonomi Indonesia masih dipublikasikan secara bulanan atau kuartalan dengan lag pelaporan yang signifikan.

Selain itu, kapasitas sumber daya manusia di lembaga pemerintah yang menguasai data science dan ML secara mendalam masih relatif terbatas dibandingkan kebutuhan transformasi digital kebijakan ekonomi. Hal ini menuntut investasi serius dalam pelatihan analis kebijakan, kolaborasi dengan akademisi, serta kemitraan strategis dengan penyedia data alternatif seperti perusahaan telekomunikasi dan platform digital untuk memperkaya basis data prediksi ekonomi nasional.

5. **Strategi Implementasi Pendekatan Hibrida**

Strategi implementasi pendekatan hibrida yang direkomendasikan mencakup tiga tahap utama: (1) *Preprocessing* data menggunakan teknik imputasi cerdas dan normalisasi *z-score* untuk mengatasi data lag dan missing values; (2) Pelatihan paralel model ML (*Random Forest*, XGBoost, ANN) dan model ekonometrika (VAR, VECM) pada dataset historis 10 tahun terakhir; serta (3) Ensemble output dengan pembobotan adaptif berdasarkan kinerja rolling window, dikombinasikan dengan modul XAI-SHAP untuk interpretabilitas kebijakan.

Rekomendasi praktis bagi institusi seperti Bank Indonesia dan Kementerian Keuangan adalah mengadopsi *platform now-casting* berbasis ML yang memperbarui proyeksi PDB secara harian menggunakan data frekuensi tinggi seperti data perpajakan *real-time*, transaksi digital, dan indeks aktivitas sektor manufaktur. Model ini kemudian dapat diintegrasikan dengan dashboard kebijakan yang menyajikan nilai kontribusi SHAP untuk setiap indikator, sehingga transparansi analitik tetap terjaga.

Pendekatan hibrida pada dasarnya merupakan upaya menjembatani dua paradigma yang selama ini sering dipandang dikotomis: inferensi ekonometrika yang berlandaskan teori versus prediksi ML yang data-driven. Mullainathan dan Spiess (2017) sendiri menekankan bahwa kedua paradigma tidak saling meniadakan, melainkan saling melengkapi ekonometrika unggul dalam menjelaskan hubungan kausal struktural, sementara ML unggul dalam menangkap pola prediktif yang kompleks. Integrasi keduanya melalui arsitektur hibrida seperti ANN+VAR memungkinkan pengambil kebijakan memperoleh manfaat dari kedua sisi sekaligus.

6. **Perbandingan dengan Konteks Negara Lain**

Pengalaman empiris di negara-negara OECD menunjukkan bahwa adopsi ML dalam forecasting makroekonomi telah berlangsung lebih sistematis melalui kolaborasi antara bank sentral dan lembaga riset independen (OECD, 2024). Beberapa bank sentral negara maju telah mengoperasikan model *now-casting* berbasis ML sebagai pelengkap (bukan pengganti) model struktural tradisional dalam rapat penetapan kebijakan moneter rutin. Pola kelembagaan semacam ini relevan untuk diadaptasi secara bertahap oleh otoritas ekonomi Indonesia, mengingat kompleksitas regulasi dan kebutuhan akuntabilitas publik yang menuntut proses transisi yang hati-hati dan terukur. Pembelajaran dari pengalaman tersebut menegaskan bahwa keberhasilan adopsi ML dalam kebijakan publik bukan sekadar persoalan teknis pemodelan, melainkan juga persoalan tata kelola kelembagaan, termasuk standar validasi model, mekanisme audit algoritma,

serta protokol komunikasi hasil prediksi kepada publik yang transparan dan dapat dipertanggungjawabkan

KESIMPULAN

Penelitian ini telah mengkaji secara komprehensif implementasi *Machine Learning* dalam prediksi pertumbuhan ekonomi. Berdasarkan analisis komparatif performa model dan kajian literatur terkini, dapat disimpulkan bahwa:

Pertama, model berbasis ML khususnya ANN dan pendekatan *ensemble* memberikan tingkat akurasi prediksi yang secara konsisten lebih tinggi (RMSE dan MAPE lebih rendah) dibandingkan model ARIMA dan VAR konvensional.

Kedua, tantangan utama implementasi ML adalah efek *black-box* yang menghambat adopsi dalam pengambilan kebijakan formal, di mana solusi *Explainable* AI (XAI-SHAP) terbukti mampu menjawab tantangan interpretabilitas tersebut.

Ketiga, pendekatan hibrida yang mengintegrasikan kekuatan inferensial ekonometrika struktural dengan fleksibilitas prediktif ML merupakan paradigma optimal untuk proyeksi PDB yang tangguh, akurat, dan akuntabel.

Keempat, keberhasilan adopsi ML dalam kebijakan ekonomi nasional sangat bergantung pada kesiapan infrastruktur data frekuensi tinggi dan kapasitas sumber daya manusia, di mana kesenjangan ini masih menjadi tantangan struktural yang harus diatasi secara bertahap di Indonesia.

Bank sentral dan kementerian keuangan perlu segera mengembangkan kapasitas analitik berbasis ML dengan berinvestasi dalam infrastruktur data berfrekuensi tinggi dan sumber daya manusia yang kompeten dalam ilmu data ekonomi. Kolaborasi antara akademisi, lembaga statistik (BPS), dan pembuat kebijakan merupakan prasyarat utama untuk mewujudkan ekosistem prediksi ekonomi yang lebih adaptif dan responsif terhadap dinamika global. Penelitian lanjutan disarankan untuk melakukan pengujian empiris langsung (bukan studi literatur) terhadap data makroekonomi Indonesia menggunakan model hibrida yang diusulkan, guna memvalidasi temuan ini pada konteks data nasional secara lebih mendalam.

DAFTAR PUSTAKA

Badan Pusat Statistik (BPS). (2025). *Metodologi Proyeksi Indikator Ekonomi Berbasis Jaringan* saraf tiruan. BPS.

Bank Indonesia. (2024). *Laporan perekonomian Indonesia 2024: Resiliensi di tengah ketidakpastian global*. Bank Indonesia.

Coulombe, P. G., Leroux, M., Stevanovic, D., & Surprenant, S. (2021). How is machine learning useful for macroeconomic forecasting? *Journal of Applied Econometrics*, 36(5), 542–564. https://doi.org/10.1002/jae.2831

Gu, S., Kelly, B., & Xiu, D. (2020). *Empirical asset pricing via machine learning*. The Review of Financial Studies, 33(5), 2223–2273. https://doi.org/10.1093/rfs/hhaa009

James, G., Witten, D., Hastie, T., & Tibshirani, R. (2023). An introduction to statistical learning with applications in Python (2nd ed.). Springer.

Kementerian Keuangan Republik Indonesia. (2025). *Laporan analisis makroekonomi dan data analytics sektor keuangan.* Kemenkeu RI.

Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2022). M5 accuracy competition: Results, findings, and conclusions. *International Journal of Forecasting*, 38(4), 1346–1364. https://doi.org/10.1016/j.ijforecast.2021.11.013

Mullainathan, S., & Spiess, J. (2017). Machine learning: An applied econometric approach. *Journal of Economic Perspectives*, 31(2), 87–106. https://doi.org/10.1257/jep.31.2.87

OECD. (2024). *Economic outlook report: Navigating inflation and low growth*. OECD Publishing.

Varian, H. R. (2014). Big data: New tricks for econometrics. *Journal of Economic Perspectives, 28(2), 3–28. https://doi.org/10.1257/jep.28.2.3*