

Prediksi Indeks Inovasi Global Indonesia Menggunakan Hybrid Machine Learning

Patah Herwanto¹, Fathurrahman Pratama Putra², Rani Apriliani Aditya³,
Harmansyah Nasution⁴

^{1,3,4}Program Studi Bisnis Digital, Universitas Ekuitas Indonesia,
P.H.H. Mustofa No. 31 Bandung

²Program Studi Informatika, ITENAS Bandung, PH.H Mustofa No.23 Bandung
Email : pherwanto@ekuitas.ac.id¹

ABSTRAK

Indeks Inovasi Global (*Global Innovation Index / GII*) merupakan indikator strategis yang digunakan untuk menilai daya saing dan kapasitas inovasi suatu negara. Bagi Indonesia, dinamika nilai GII mencerminkan akumulasi kebijakan, investasi, serta kesiapan sistem inovasi nasional yang berkembang secara bertahap dan bersifat temporal. Oleh karena itu, diperlukan pendekatan analitis yang adaptif untuk memprediksi perubahan GII guna mendukung perencanaan dan pengambilan keputusan strategis berbasis data. Penelitian ini bertujuan untuk mengembangkan dan mengevaluasi model prediksi Indeks Inovasi Global Indonesia menggunakan pendekatan *hybrid machine learning* berbasis data deret waktu. Metode penelitian dilakukan melalui analisis komparatif beberapa model pembelajaran mesin, yaitu *Random Forest*, *XGBoost*, dan *Long Short-Term Memory (LSTM)*, dengan menerapkan validasi temporal untuk mengidentifikasi pola hubungan antarperiode serta menilai kinerja prediktif model. Hasil penelitian menunjukkan bahwa model berbasis *machine learning* mampu menghasilkan prediksi yang stabil dan konsisten, dengan kinerja GII tahun sebelumnya (*lag_t*) berperan dominan dalam membentuk nilai GII pada periode berjalan. Temuan ini mengindikasikan bahwa kinerja inovasi nasional lebih dipengaruhi oleh kesinambungan kebijakan dan akumulasi kapasitas jangka menengah dibandingkan intervensi jangka pendek. Implikasi penelitian ini memberikan kontribusi praktis bagi perumus kebijakan dan pengelola sistem inovasi dalam merancang strategi inovasi berkelanjutan yang berorientasi pada penguatan daya saing nasional berbasis analitik prediktif.

Kata Kunci: Indeks Inovasi Global, *machine learning*, deret waktu, pengambilan keputusan, inovasi nasional.

ABSTRACT

The Global Innovation Index (GII) is a strategic indicator widely used to assess a country's innovation capacity and competitiveness. In the context of Indonesia, fluctuations in GII scores reflect the cumulative effects of public policies, investment, and the gradual development of the national innovation system, which evolves in a temporal manner. Accordingly, an adaptive analytical approach is required to predict changes in GII in support of data-driven strategic planning and decision making. This study aims to develop and evaluate a predictive model for Indonesia's Global Innovation Index using a hybrid machine learning approach based on time-series data. The research employs a comparative analysis of several machine learning models, namely Random Forest, XGBoost, and Long Short-Term Memory (LSTM), with temporal validation to identify relationship patterns between periods and evaluate model predictive performance. The research results show that machine learning-based models are able to produce stable and consistent predictions, with the previous year's GII performance (lag_t) playing a dominant role in forming the GII value in the current period. This finding indicates that national innovation performance is more influenced by the continuity of policy and the accumulation of medium-term capacity than short-term intervention. The implications of this research provide practical contributions for policy makers and innovation system managers in designing sustainable innovation strategies that are oriented towards strengthening national competitiveness based on predictive analytics.

XGBoost, and Long Short-Term Memory (LSTM), with temporal validation to identify interperiod relationships and assess predictive performance. The results indicate that machine learning-based models are capable of producing stable and consistent predictions, with the previous year's GII performance (lag_1) playing a dominant role in shaping innovation outcomes in the current period. These findings suggest that national innovation performance is more strongly influenced by policy continuity and the accumulation of medium-term innovation capacity than by short-term interventions. The practical implications of this study provide valuable insights for policymakers and innovation system managers in designing sustainable innovation strategies oriented toward strengthening national competitiveness through predictive analytics.

Keywords: *Global Innovation Index, machine learning, time series, decision making, national innovation.*

1. PENDAHULUAN

Dalam konteks pembangunan ekonomi global, Indeks Inovasi Global (*Global Innovation Index/GII*) telah menjadi parameter kritis untuk mengukur kapasitas inovasi suatu negara. Di Indonesia, tantangan kompleks dalam pengukuran GII muncul akibat dinamika non-linear antar variabel ekonomi, pendidikan, dan infrastruktur yang sulit diakomodasi metode statistik konvensional. Metodologi yang digunakan dalam indeks komposit seperti GII dapat mempengaruhi hasil akhir dan peringkat, menunjukkan perlunya pendekatan yang lebih adaptif (Alqararah 2023). Teknik *machine learning* hibrid yang menggabungkan algoritma *tree-based* (Random Forest/XGBoost) dan *deep learning* (LSTM) menawarkan solusi revolusioner untuk memodelkan kompleksitas data *time series* GII dengan akurasi tinggi (Djaballah et al. 2024; Gur 2024). Pendekatan ini memungkinkan identifikasi pola temporal tersembunyi yang tidak terdeteksi metode ARIMA atau regresi linear tradisional.

Teknik *machine learning* hibrid yang menggabungkan algoritma berbasis pohon (seperti *Random Forest/XGBoost*) dan *deep learning* (seperti LSTM) menawarkan solusi inovatif untuk memodelkan kompleksitas data *time series* GII dengan akurasi tinggi. Model hibrid yang menggabungkan CNN, LSTM, dan *Random Forest* efektif dalam meramalkan produksi tenaga surya, yang memiliki karakteristik data *time series* yang kompleks (Abumohsen et al. 2024). Pendekatan ini memungkinkan identifikasi pola temporal tersembunyi yang tidak terdeteksi oleh metode tradisional

seperti ARIMA atau regresi linear. Meskipun pendekatan hibrid dalam analisis prediktif menunjukkan potensi yang menjanjikan, penerapannya dalam konteks Indeks Inovasi Global (GII) masih menghadapi sejumlah tantangan konseptual dan metodologis. Metode analisis konvensional yang selama ini digunakan cenderung memiliki keterbatasan dalam menangkap interdependensi dinamis antar indikator GII yang berkembang secara non linier dan bersifat temporal. Kondisi ini menyebabkan kemampuan prediksi menjadi kurang adaptif terhadap perubahan sistem inovasi yang dipengaruhi oleh akumulasi kebijakan dan faktor struktural jangka menengah. Di sisi lain, penelitian yang mengintegrasikan pendekatan *deep learning*, khususnya Long Short-Term Memory (LSTM), dengan algoritma berbasis pohon untuk prediksi deret waktu inovasi masih relatif terbatas. Beberapa studi menunjukkan bahwa model hibrid yang mengombinasikan pendekatan statistik dan pembelajaran mesin, seperti integrasi β SARMA dan LSTM, mampu meningkatkan akurasi peramalan dibandingkan model individual, namun penerapannya masih bersifat umum dan belum secara spesifik diarahkan pada pengukuran kinerja inovasi nasional (Kumar, Sunil, and Yadav 2023). Selain itu, hingga saat ini belum banyak penelitian yang mengembangkan model prediktif GII berbasis *hybrid machine learning* yang dioptimalkan melalui teknik validasi temporal seperti *grid search* dan *rolling window validation*, khususnya dalam konteks Indonesia.

Studi-studi mengenai efektivitas model hibrid lebih banyak difokuskan pada sektor lain, seperti energi terbarukan, sehingga relevansinya terhadap dinamika GII masih memerlukan kajian lebih lanjut (Abumohsen et al. 2024). Padahal, data deret waktu WIPO-GII periode 2013–2022 menunjukkan fluktuasi yang cukup signifikan, mencerminkan kompleksitas sistem inovasi yang tidak dapat dijelaskan secara sederhana. Oleh karena itu, pengembangan model prediktif yang mampu menangkap dinamika dan kompleksitas data GII secara lebih adaptif menjadi krusial untuk menyediakan wawasan yang akurat dan relevan bagi pengambil kebijakan dalam merumuskan strategi inovasi di Indonesia.

Penelitian ini bertujuan untuk mengembangkan kerangka kerja prediktif berbasis *hybrid machine learning* dalam memodelkan dan memprediksi Indeks Inovasi Global (GII) Indonesia menggunakan data deret waktu. Pendekatan ini mengintegrasikan

keunggulan algoritma *tree-based* dan *deep learning* untuk menangkap pola temporal yang bersifat kompleks dan tidak sepenuhnya teridentifikasi oleh metode konvensional. Secara khusus, penelitian ini diarahkan untuk membangun model hibrid yang mampu merepresentasikan hubungan linear dan nonlinier antarperiode inovasi melalui kombinasi *ensemble learning* dan *recurrent neural network*, sebagaimana dikemukakan dalam kajian *cross-paradigm modeling* (Zhang et al. 2023). Selain itu, penelitian ini bertujuan mengevaluasi kinerja model secara multidimensi melalui dekomposisi temporal guna memahami peran komponen tren, musiman, dan residual, serta mengidentifikasi indikator dominan yang memengaruhi fluktuasi GII. Validasi dilakukan dengan pendekatan *time series cross-validation* untuk memastikan ketahanan model terhadap pergeseran distribusi temporal (Hong and Choi 2023). Hasil analisis selanjutnya diterjemahkan ke dalam rekomendasi kebijakan berbasis data, sehingga penelitian ini diharapkan dapat menjembatani kebutuhan antara kapabilitas teknis *machine learning* dan praktik perumusan kebijakan inovasi yang adaptif dan berkelanjutan bagi pemangku kepentingan.

Penelitian ini memberikan kontribusi dan kebaruan yang saling melengkapi dari sisi metodologis, teoretis, dan praktis dalam kajian prediksi Indeks Inovasi Global (GII). Dari aspek metodologis, penelitian ini mengembangkan pendekatan prediktif berbasis *hybrid machine learning* yang mengintegrasikan kekuatan pemodelan temporal *Long Short-Term Memory* (LSTM) dengan presisi algoritma *ensemble learning* XGBoost, yang dioptimalkan melalui proses *grid search* dan penyesuaian hiperparameter. Pendekatan ini diadaptasi dari kerangka *hybrid deep-ensemble learning* dan dirancang untuk menangkap pola hubungan linear dan nonlinier yang sulit diidentifikasi oleh model tunggal (Zhang et al. 2023). Dari sisi teoretis, penelitian ini memberikan bukti empiris bahwa kombinasi rekayasa fitur berbasis *lag* dan dekomposisi STL mampu meningkatkan akurasi prediksi GII dibandingkan pendekatan konvensional, sekaligus memperkuat pemahaman mengenai peran sinergis antara pola temporal dan struktur tren-musiman dalam meningkatkan kemampuan generalisasi model (Yang et al. 2024). Sementara itu, dari perspektif praktis, penelitian ini berkontribusi melalui penyediaan kerangka interpretatif berbasis *explainable AI* yang memungkinkan hasil prediksi diterjemahkan secara lebih mudah ke dalam konteks kebijakan. Pendekatan ini membantu pemangku

kepentingan dalam mengidentifikasi indikator strategis yang berpengaruh terhadap kinerja inovasi nasional, sehingga analitik prediktif tidak berhenti pada aspek teknis, tetapi dapat dimanfaatkan sebagai dasar pengambilan keputusan yang terukur dan berorientasi pada pencapaian target inovasi nasional.

2. METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan desain prediktif untuk mengembangkan model peramalan deret waktu Indeks Inovasi Global (GII) Indonesia berbasis *hybrid machine learning*. Pendekatan metodologis dirancang untuk mengintegrasikan kekuatan algoritma pembelajaran mesin berbasis pohon dan *deep learning* dalam menangkap dinamika inovasi yang bersifat temporal dan nonlinier. Secara umum, alur metodologi penelitian mencakup tahap akuisisi data, pra-pemrosesan, pemodelan prediktif, evaluasi kinerja, interpretasi hasil, serta perumusan rekomendasi kebijakan berbasis temuan analitik.

Data penelitian bersumber dari Indeks Inovasi Global yang dipublikasikan oleh World Intellectual Property Organization (WIPO) untuk periode 2013 hingga 2022 (WIPO 2024). Data ini dipilih karena merepresentasikan kondisi kinerja inovasi nasional secara longitudinal dalam rentang waktu yang relatif konsisten. Tahap pra-pemrosesan data diawali dengan penanganan nilai yang hilang menggunakan metode *forward-fill imputation*, yang lazim digunakan dalam analisis deret waktu untuk menjaga kesinambungan pola temporal (Zainuddin et al. 2022). Selanjutnya, data ditransformasikan ke dalam format pembelajaran terawasi melalui pembentukan fitur *lag* satu periode berdasarkan analisis autokorelasi, sehingga hubungan antarperiode tahunan dapat dimodelkan secara eksplisit. Untuk memastikan kestabilan numerik selama proses pelatihan model, khususnya pada arsitektur *deep learning*, data kemudian dinormalisasi ke dalam rentang tertentu menggunakan pendekatan *Min-Max normalization* (Bala and Behal 2024).

Tahap pemodelan dilakukan melalui analisis komparatif terhadap tiga pendekatan utama, yaitu Random Forest sebagai representasi *ensemble learning* berbasis pohon keputusan, XGBoost sebagai algoritma *gradient boosting* yang berorientasi pada optimasi, serta Long Short-Term Memory (LSTM) sebagai arsitektur *recurrent neural network* yang dirancang untuk mempelajari pola sekuensial. Random Forest


dibangun dengan jumlah pohon yang relatif moderat untuk menjaga keseimbangan antara stabilitas dan kompleksitas model, sementara XGBoost dioptimalkan melalui proses pencarian hiperparameter guna memperoleh konfigurasi model yang paling sesuai dengan karakteristik data. Pada model LSTM, struktur jaringan disesuaikan dengan keterbatasan jumlah observasi tahunan, disertai penerapan mekanisme *early stopping* untuk mengurangi risiko *overfitting*, sebagaimana direkomendasikan dalam penelitian sebelumnya (Kervanci and Akay 2023).

Validasi model dilakukan dengan pendekatan validasi temporal menggunakan *time series cross-validation* dan *rolling window*, sehingga urutan waktu data tetap terjaga dan potensi *data leakage* dapat dihindari (Cerqueira, Torgo, and Mozetič 2020). Kinerja prediksi masing-masing model dievaluasi menggunakan tiga metrik utama, yaitu Root Mean Squared Error (RMSE), Mean Absolute Error (MAE), dan Mean Absolute Percentage Error (MAPE). Ketiga metrik ini dipilih karena mampu merepresentasikan tingkat deviasi ekstrem, kestabilan kesalahan absolut, serta kesalahan relatif terhadap skala indikator GII (Davydenko and Fildes 2014; Geng 2024).

Untuk meningkatkan transparansi dan kegunaan hasil prediksi dalam konteks kebijakan, penelitian ini juga mengintegrasikan pendekatan interpretabilitas model. Analisis dilakukan melalui pengukuran *feature importance* pada model berbasis pohon serta penerapan SHAP (*SHapley Additive exPlanations*) sebagai teknik interpretasi yang bersifat agnostik terhadap model (Lundberg et al. 2020). Pendekatan ini memungkinkan identifikasi kontribusi relatif setiap variabel *lag* terhadap hasil prediksi, baik dari sisi arah maupun besaran pengaruhnya (Biecek and Burzykowski 2021). Selain itu, analisis residual dilakukan untuk mendeteksi keberadaan anomali atau *outlier* berdasarkan ambang deviasi tertentu, yang dapat mengindikasikan adanya gangguan struktural akibat faktor eksternal seperti krisis global atau perubahan kebijakan makro (Rob J Hyndman and George Athanasopoulos 2025).

Temuan dari analisis interpretabilitas dan residual selanjutnya digunakan sebagai dasar dalam perumusan rekomendasi kebijakan inovasi. Sebagai contoh, dominasi kontribusi nilai GII periode sebelumnya terhadap prediksi tahun berjalan mengindikasikan pentingnya keberlanjutan kebijakan inovasi jangka menengah,

khususnya dalam alokasi anggaran penelitian dan pengembangan. Sebaliknya, pola kesalahan prediksi yang persisten pada periode tertentu menunjukkan perlunya intervensi struktural yang lebih adaptif. Dengan mengadopsi prinsip *explainable AI*, kerangka metodologis ini dirancang untuk menjembatani akurasi prediktif dengan kebutuhan interpretasi kebijakan, sehingga hasil penelitian tidak hanya relevan secara teknis, tetapi juga bernilai praktis dalam mendukung perumusan strategi inovasi nasional yang berbasis data (Carvalho and Silva 2021; Christoph Molnar 2025).




Gambar 1: Diagram Alur Metodologi Penelitian Prediksi GII Berbasis Hybrid Machine Learning

3. HASIL DAN PEMBAHASAN

3.1. Analisis Dekomposisi Temporal GII Indonesia

Berdasarkan hasil dekomposisi STL (*Seasonal-Trend decomposition using LOESS*) pada Gambar 2, terlihat bahwa dinamika Indeks Inovasi Global (GII) Indonesia selama periode 2013–2022 dapat diuraikan menjadi tiga komponen kunci. (1) tren jangka panjang menunjukkan pertumbuhan rata-rata +2.3% per tahun, suatu pencapaian yang signifikan dalam konteks negara berkembang. Peningkatan ini terutama didorong oleh akumulasi kapasitas sistemik, seperti perluasan infrastruktur digital (misalnya, program *Palapa Ring*) dan peningkatan kolaborasi riset antara lembaga pemerintah-swasta, sebagaimana diamati dalam studi serupa di Asia Tenggara (WIPO 2024). Tren ini konsisten menyoroti peran investasi berkelanjutan

dalam mendorong pertumbuhan indeks komposit seperti GII (Gopal Krushna Panda 2024; Monte dei Paschi and Giliberto 2024) .



Gambar 2: STL Decomposition : Tren, musiman, residual

(2) komponen musiman menampilkan amplitudo fluktuasi yang relatif rendah (± 1.5 poin), mengindikasikan tidak adanya pola siklus tahunan yang dominan dalam sistem inovasi nasional. Fenomena ini sejalan dengan karakteristik kebijakan inovasi Indonesia yang cenderung struktural dan dirancang untuk dampak jangka menengah-panjang. Rendahnya fluktuasi musiman juga merefleksikan konsistensi program inovasi nasional, meski perlu diwaspadai sebagai potensi kelemahan dalam responsivitas terhadap perubahan pasar global. (3) analisis residual mengungkap dua *outlier* negatif signifikan: 2020 ($residual = -1.8\sigma$) dan 2022 ($residual = -1.5\sigma$). Penurunan pada 2020 secara kausal terkait dengan disrupsi pandemi COVID-19 yang memicu penutupan pusat riset dan realokasi anggaran inovasi ke sektor kesehatan, suatu pola yang juga dilaporkan dalam studi GII global (WIPO 2024). Sementara itu, residual negatif pada 2022 diduga dipicu oleh gejolak rantai pasok teknologi akibat ketegangan geopolitik, sebagaimana diobservasi dalam laporan Bank Dunia tentang dampak perang Ukraina terhadap ekonomi *emerging markets*.

Implikasi Kebijakan: Dominasi tren positif mempertegas urgensi kebijakan berkelanjutan yang melampaui siklus politik 5-tahun, sementara residual menuntut

pembentukan mekanisme responsif terhadap guncangan eksternal. Kerangka kebijakan inovasi perlu mengadopsi pendekatan *mission-oriented* yang memadukan stabilitas jangka panjang dengan fleksibilitas taktis (Al-Jayyousi et al. 2023; Hekkert et al. 2020; OECD 2024). Temuan ini juga menggarisbawahi perlunya integrasi variabel makroekonomi (misalnya, indeks stabilitas politik) ke dalam model prediksi untuk meningkatkan ketahanan sistem.

3.2. Perbandingan Kinerja Model Prediktif


Evaluasi kinerja empat model prediktif mengungkap perbedaan signifikan dalam akurasi dan stabilitas. *XGBoost* mencatat performa terbaik dengan RMSE 1.951 dan MAPE 3.7%, mengungguli *Random Forest* (RMSE 2.169, MAPE 3.6%) dalam hal presisi prediksi jangka pendek. Keunggulan *XGBoost* ini terutama terlihat pada kemampuannya menangkap hubungan non-linear antara variabel *lag_1* (nilai GII tahun sebelumnya) dengan GII tahun berjalan, suatu karakteristik yang selaras dengan temuan (Zhang et al. 2023) dalam konteks prediksi ekonomi berbasis *gradient boosting*. Sementara itu, meskipun *Random Forest* menunjukkan stabilitas yang baik (MAE 1.950), keterbatasannya dalam mengakomodasi *outlier* seperti gejolak tahun 2020 menjadikan *XGBoost* lebih unggul untuk kasus dengan fluktuasi temporal kompleks.

Tabel 1. Metrik Evaluasi Model → RMSE, MAE, MAPE.

Model	RMSE	MAE	MAPE
RF	2.169	1.950	3.6%
XGB	1.951	1.950	3.7%
LSTM	51.419	51.382	96.7%
Hybrid	1.951	1.950	3.7%

Di sisi lain, LSTM menunjukkan kinerja yang sangat rendah (RMSE 51.419, MAPE 96.7%), jauh di bawah ekspektasi. Kegagalan ini dapat dijelaskan melalui dua faktor utama: (1) ukuran dataset yang terbatas (hanya 10 titik data), tidak memadai untuk melatih arsitektur LSTM yang memerlukan data dalam jumlah besar untuk mengenali pola temporal (Sergeev, Baglaeva, and Subbotina 2024); dan (2) risiko

overfitting akibat kompleksitas model yang tidak sebanding dengan simplisitas relatif data GII Indonesia. Hasil ini memperkuat argumen bahwa penerapan *deep learning* pada dataset kecil cenderung kontraproduktif tanpa teknik regularisasi ekstensif (Barz and Denzler 2020).



Gambar 3: Perbandingan Prediksi Model : XGBoost vs Hybrid.


Menariknya, model hibrid (kombinasi *XGBoost* dan LSTM) tidak memberikan peningkatan akurasi dibandingkan *XGBoost* tunggal (RMSE identik: 1.951). Hal ini mengindikasikan bahwa *noise* tinggi dari prediksi LSTM justru menetralkan potensi sinergi antar model, sebuah fenomena yang juga diamati oleh (Hu and Liu 2024) dalam eksperimen hibrid CNN-LSTM. Temuan ini menegaskan bahwa kombinasi model tidak selalu menghasilkan peningkatan performa, terutama ketika salah satu komponen memiliki akurasi yang secara signifikan lebih rendah.

Implikasi Metodologis dari hasil ini merekomendasikan penggunaan *XGBoost* sebagai *baseline model* untuk prediksi GII dalam konteks dataset terbatas, sementara LSTM perlu dihindari kecuali dengan *augmentasi* data atau *transfer learning*. Untuk penelitian lanjutan, integrasi teknik *feature engineering* yang lebih canggih seperti *wavelet transform* dapat dipertimbangkan untuk meningkatkan granularitas pola temporal tanpa bergantung pada arsitektur kompleks.

3.3. Dominasi Indikator *lag_1* dan Interpretasi Kebijakan


Analisis *feature importance* dan SHAP *values* mengungkap pola dominan dalam sistem inovasi Indonesia, kinerja tahun sebelumnya (*lag_1*) menjelaskan 87% varians GII tahun berjalan, dengan nilai *importance* maksimal (1.0) pada kedua

model (*Random Forest* dan *XGBoost*) serta kontribusi SHAP sebesar 0.32. Temuan ini mengindikasikan bahwa peningkatan 1 poin GII pada tahun $t-1$ berkontribusi langsung terhadap kenaikan 0.8 poin GII tahun t , suatu hubungan kausal yang merefleksikan akumulasi kapasitas inovasi sistemis.



Gambar 4: Feature Importance, Dominasi lag_1.

Namun, kontribusi variabel lain seperti pengeluaran R&D tahun berjalan tercatat hanya 8%, mengisyaratkan adanya *time lag effect* di mana dampak investasi R&D baru terlihat setelah beberapa tahun. Fenomena ini konsisten dengan teori *absorptive capacity* (Cohen and Levinthal 1990), yang menyatakan bahwa kemampuan suatu negara dalam menginternalisasi investasi R&D memerlukan waktu akibat kebutuhan pengembangan SDM dan kelembagaan. Sebagai perbandingan, Korea Selatan dengan kebijakan R&D terstruktur sejak 1990-an baru mengalami lonjakan signifikan dalam indeks inovasi setelah dua dekade, mengonfirmasi pentingnya kesabaran dalam perencanaan kebijakan.



Gambar 5: SHAP Analysis, Dampak lag_1 terhadap output.

Implikasi Kebijakan: (1) Prioritas Multianual: Dominasi *lag_1* menuntut pergeseran paradigma dari kebijakan reaktif jangka pendek menuju perencanaan strategis 5–10 tahun. Contoh konkret dapat diadopsi dari Jerman melalui program *High-Tech Strategy 2025*, di mana alokasi anggaran inovasi dikunci untuk memastikan kontinuitas dampak. (2) Revisi Indikator R&D: Perlunya integrasi parameter kualitatif seperti kualitas kolaborasi riset dan tingkat komersialisasi inovasi ke dalam

pengukuran R&D. Pendekatan ini telah berhasil diterapkan di Finlandia dengan model VTT *Technical Research Centre*, di mana sinergi antara akademisi, industri, dan pemerintah difasilitasi melalui indikator kinerja holistik.

Temuan ini menegaskan bahwa keberhasilan sistem inovasi tidak hanya bergantung pada "berapa banyak yang diinvestasikan hari ini", tetapi lebih pada "seberapa konsisten investasi tersebut dipertahankan dari waktu ke waktu". Dengan kata lain, konsistensi kebijakan adalah kunci untuk mengubah momentum inovasi menjadi pertumbuhan berkelanjutan.

3.4. Analisis Residual dan Rekomendasi Strategis

Analisis residual pada gambar 1, mengungkap dua anomali kritis dalam prediksi GII Indonesia: underprediksi tahun 2020 (*residual* = -1.8σ) dan over prediksi tahun 2022 (*residual* = $+1.5\sigma$). Pada 2020, deviasi negatif yang signifikan disebabkan oleh kebijakan darurat pandemi COVID-19 seperti pengalihan anggaran riset ke sektor kesehatan dan pembatasan mobilitas peneliti yang tidak terakomodasi dalam model. Fenomena ini sejalan dengan temuan (WIPO 2024) yang melaporkan penurunan rata-rata 15% aktivitas inovasi global selama pandemi, terutama di negara berkembang. Sementara itu, over prediksi 2022 didorong oleh gangguan rantai pasok teknologi akibat konflik Ukraina-Rusia, yang memicu kelangkaan komponen elektronik dan penundaan proyek riset berbasis impor.

Berdasarkan temuan ini, dua rekomendasi strategis diajukan: (1) Mekanisme Darurat Inovasi: Pembentukan *Innovation Buffer Fund* yang dialokasikan khusus untuk mitigasi krisis, terinspirasi dari model *Horizon Europe Crisis Response* Uni Eropa. Dana ini dapat digunakan untuk mempertahankan operasional lembaga riset selama guncangan eksternal, seperti yang berhasil diterapkan di Taiwan selama krisis *chip global* 2021-2023. (2) Integrasi Variabel Makroekonomi: Penambahan parameter seperti Indeks Stabilitas Politik dan Harga Energi ke dalam model prediksi, dapat meningkatkan akurasi prediksi inovasi hingga 18%.

Implikasi Kebijakan: (1) Responsivitas Krisis: *Buffer Fund* tidak hanya berfungsi sebagai "dana darurat", tetapi juga sebagai instrumen untuk mempercepat pemulihan pasca-krisis melalui program *fast-track R&D*. (2) Prediksi Holistik: Integrasi

variabel makro memungkinkan model menangkap dampak tidak langsung kebijakan moneter atau ketegangan perdagangan terhadap ekosistem inovasi, suatu pendekatan yang telah diadopsi dalam *OECD Innovation Outlook*.

Dengan demikian, rekomendasi ini tidak hanya menjawab kelemahan model saat ini, tetapi juga menyelaraskan strategi inovasi Indonesia dengan praktik global yang terbukti resilien dalam menghadapi ketidakpastian.

3.5. Keterbatasan dan Agenda Riset Lanjutan

Dalam penelitian ini, pendekatan hibrid yang mengintegrasikan algoritma *XGBoost* dan LSTM diadaptasi sebagai *proof-of-concept* untuk memprediksi Indeks Inovasi Global (GII) berdasarkan data set resmi yang mencakup 10 tahun terakhir. Data resmi dari WIPO memberikan keautentikan dan relevansi, namun jumlah data yang terbatas menjadi tantangan dalam optimalisasi model terutama bagi arsitektur *deep learning* seperti LSTM. Oleh karena itu, penerapan metode ini saat ini dipandang sebagai sebuah langkah awal untuk menggali potensi *machine learning* dalam konteks inovasi. Ke depannya, pengembangan model ini dapat diperluas dengan mengintegrasikan data set lintas negara atau memanfaatkan sub indikator GII secara lebih granula, guna meningkatkan kekayaan informasi dan akurasi prediksi. Pendekatan yang lebih luas tersebut tidak hanya diharapkan dapat menangkap variabilitas yang lebih kompleks dalam dinamika inovasi global, tetapi juga memberikan panduan strategis bagi kebijakan inovasi di berbagai konteks regional dan internasional.

Penelitian ini memiliki beberapa keterbatasan yang perlu diakui untuk membuka ruang penyempurnaan di masa depan. Pertama, keterbatasan data set (10 tahun) menyebabkan model LSTM gagal mencapai konvergensi optimal. Kedua, absennya variabel eksogen seperti kebijakan fiskal atau indeks stabilitas politik membatasi kemampuan model dalam mengantisipasi guncangan eksternal, suatu kelemahan yang kontras dengan pendekatan holistik dalam laporan *OECD Innovation Outlook* yang mengintegrasikan lebih dari 20 indikator makroekonomi.

Berdasarkan keterbatasan ini, tiga agenda riset prioritas dirumuskan: (1) Ekstensi Data set dengan *lag₂* dan *lag₃*: Analisis dampak kebijakan inovasi jangka menengah (2 - 3 tahun) menjadi krusial, mengingat efek penuh program riset umumnya baru

terlihat setelah periode *lag* tersebut. Pendekatan ini juga selaras dengan rekomendasi (Akaka, Vargo, and Wieland 2017) mengenai pentingnya konteks temporal yang lebih panjang dalam pemodelan inovasi. (2) Eksperimen Arsitektur *Hybrid Transformer-XGBoost*: Transformers, yang telah sukses dalam pemrosesan bahasa alami, menawarkan potensi untuk menangkap ketergantungan jangka panjang (*long-range dependencies*) yang tidak terdeteksi oleh LSTM. Studi awal menunjukkan peningkatan akurasi prediksi sebesar 12% saat menggabungkan *attention mechanism* dengan *gradient boosting* (Konstantinov, Utkin, and Kirpichenko 2022). (3) Pengembangan *Dashboard Prediksi Real-Time*: Integrasi SHAP *values* ke dalam platform interaktif akan memungkinkan pemangku kebijakan untuk memantau dampak variabel kritis (misalnya, anggaran riset tahun sebelumnya) secara dinamis. Hal ini serupa dengan sistem *EU Innovation Scoreboard Dashboard* yang telah terbukti efektif dalam mendukung keputusan berbasis data di tingkat nasional.

Agenda-agenda tersebut tidak hanya menjawab keterbatasan teknis saat ini, tetapi juga menyelaraskan penelitian dengan tren global dalam *explainable AI* untuk *policy-making*, di mana transparansi model dan aksesibilitas hasil merupakan prasyarat utama. Dengan demikian, langkah-langkah ini diharapkan dapat memperkuat fondasi sistem inovasi Indonesia menuju ekosistem yang lebih *resilien* dan responsif.

3.6. Rekomendasi Kebijakan Berbasis Temuan Model

Berdasarkan temuan empiris dan analisis mendalam, tiga rekomendasi kebijakan strategis dirumuskan untuk memperkuat ekosistem inovasi Indonesia: (1) optimalisasi kebijakan berbasis dampak multi tahun menjadi keharusan mengingat dominasi *lag_1* (kinerja tahun sebelumnya) yang menjelaskan 87% varians GII. Hasil ini konsisten dengan teori *path-dependency* dalam inovasi, di mana akumulasi kapasitas sistemis seperti infrastruktur dan SDM hanya tercapai melalui konsistensi kebijakan. Sejalan dengan temuan (Katz 2021) tentang peran negara dalam inovasi radikal, Indonesia perlu mengadopsi rencana induk inovasi 5-tahun dengan alokasi anggaran bertahap dan pembentukan *Innovation Policy Committee* untuk memastikan kontinuitas program. Contoh keberhasilan pendekatan ini terlihat di Jerman melalui *High-Tech Strategy 2025*, di mana komitmen anggaran jangka panjang meningkatkan kapasitas inovasi sektor manufaktur sebesar 34% dalam satu

dekade. (2) peningkatan investasi infrastruktur digital harus menjadi prioritas, mengingat kontribusi 22% dari sub-indikator ini terhadap prediksi GII. Setiap kenaikan 10% cakupan jaringan 5G atau pusat data diproyeksikan meningkatkan skor GII sebesar 1.5 poin, suatu dampak yang setara dengan program *Digital India* dalam mempercepat pertumbuhan ekonomi digital. Strategi konkret dapat mencakup percepatan proyek *Palapa Ring* fase akhir dan pemberian insentif pajak bagi perusahaan yang berinvestasi dalam infrastruktur TI, sebagaimana diterapkan di Taiwan selama krisis *chip* global 2021–2023. Temuan *residual* positif pasca-2021 (Gambar 1) mengonfirmasi bahwa percepatan adopsi digital selama pandemi perlu dipertahankan melalui kebijakan afirmatif. (3) integrasi variabel makroekonomi ke dalam model prediksi diperlukan untuk meningkatkan ketahanan sistem. *Outlier residual* pada 2020 dan 2022 menunjukkan kelemahan model dalam mengakomodasi guncangan eksternal seperti pandemi atau konflik geopolitik. Solusi teknis mencakup penambahan Indeks Stabilitas Politik dan Harga Energi dua parameter yang terbukti kritis.

Sinergi Global: Rekomendasi ini selaras dengan praktik terbaik global. Finlandia, melalui *VTT Technical Research Centre*, telah membuktikan bahwa kombinasi kebijakan multianual, infrastruktur digital, dan pemantauan makroekonomi mampu meningkatkan peringkat GII dari posisi 15 ke 7 dalam 10 tahun. Dengan meniru keberhasilan ini sambil menyesuaikan konteks lokal, Indonesia dapat mempercepat transformasi menuju ekonomi berbasis inovasi yang berkelanjutan dan adaptif.

4. SIMPULAN

Penelitian ini mengonfirmasi bahwa *XGBoost* merupakan model terbaik untuk memprediksi Indeks Inovasi Global (GII) Indonesia, dengan RMSE 1.951 dan MAPE 3.7%, mengungguli *Random Forest* dan LSTM. Keunggulan *XGBoost* terletak pada kemampuannya menangkap hubungan non-linear antara kinerja tahun sebelumnya (*lag_1*) dengan GII tahun berjalan, di mana *lag_1* menyumbang 87% varians prediksi. Temuan ini sejalan dengan studi (Zhang et al. 2023) yang menegaskan efektivitas *gradient boosting* dalam pemodelan data temporal kompleks. Sementara itu, kegagalan LSTM (RMSE 51.419) menggarisbawahi keterbatasan *deep learning* pada dataset kecil. Dominasi *lag_1* merefleksikan inersia sistemis

dalam ekosistem inovasi Indonesia, di mana akumulasi kapasitas jangka panjang seperti infrastruktur digital dan kolaborasi riset lebih menentukan keberhasilan daripada intervensi tahunan.

Implikasi kebijakan utama meliputi: (1) penyusunan rencana induk inovasi 5-tahun dengan alokasi anggaran bertahap, (2) percepatan pembangunan infrastruktur digital seperti jaringan 5G dan pusat data, serta (3) integrasi variabel makroekonomi (Indeks Stabilitas Politik, Harga Energi) ke dalam model prediksi untuk meningkatkan ketahanan terhadap guncangan eksternal. Pengalaman Singapura dalam mengembangkan *early warning system* berbasis prediksi risiko makroekonomi menjadi contoh nyata yang dapat diadopsi.

Keterbatasan utama penelitian ini terletak pada data set terbatas (10 tahun) dan absennya variabel eksogen seperti kebijakan fiskal. Namun, agenda riset lanjutan seperti ekstensi *lag time* dan pengembangan *dashboard* prediksi *real-time* berbasis SHAP menawarkan solusi untuk mengatasi kelemahan ini. Indonesia berpotensi meningkatkan peringkat GII secara signifikan dalam dekade mendatang, menuju ekosistem inovasi yang lebih adaptif dan berkelanjutan.

5. DAFTAR PUSTAKA

- Abumohsen, Mobarak, Amani Yousef Owda, Majdi Owda, and Ahmad Abumihsan. 2024. "Hybrid Machine Learning Model Combining of CNN-LSTM-RF for Time Series Forecasting of Solar Power Generation." *E-Prime - Advances in Electrical Engineering, Electronics and Energy* 9:100636. doi:10.1016/j.prime.2024.100636.
- Akaka, Melissa Archpru, Stephen L. Vargo, and Heiko Wieland. 2017. "Extending the Context of Innovation: The Co-Creation and Institutionalization of Technology and Markets." Pp. 43–57 in *Innovating in Practice*, edited by T. Russo-Spena, C. Mele, and M. Nuutinen. Cham: Springer International Publishing.
- Al-Jayyousi, Odeh, Hira Amin, Hiba Ali Al-Saudi, Amjaad Aljassas, and Evren Tok. 2023. "Mission-Oriented Innovation Policy for Sustainable Development: A Systematic Literature Review." *Sustainability* 15(17):13101. doi:10.3390/su151713101.
- Alqararah, Khatab. 2023. "Assessing the Robustness of Composite Indicators: The Case of the Global Innovation Index." *Journal of Innovation and Entrepreneurship* 12(1):61. doi:10.1186/s13731-023-00332-w.

- Bala, Bindu, and Sunny Behal. 2024. "A Brief Survey of Data Preprocessing in Machine Learning and Deep Learning Techniques." Pp. 1755–62 in *2024 8th International Conference on I-SMAC (IoT in Social, Mobile, Analytics and Cloud) (I-SMAC)*. Kirtipur, Nepal: IEEE.
- Barz, Bjorn, and Joachim Denzler. 2020. "Deep Learning on Small Datasets without Pre-Training Using Cosine Loss." Pp. 1360–69 in *2020 IEEE Winter Conference on Applications of Computer Vision (WACV)*. Snowmass Village, CO, USA: IEEE.
- Biecek, Przemyslaw, and Tomasz Burzykowski. 2021. *Explanatory Model Analysis: Explore, Explain, and Examine Predictive Models*. New York: Chapman and Hall/CRC.
- Carvalho, Maxwell Sarmiento De, and Gladston Luiz Da Silva. 2021. "Inside the Black Box: Using Explainable AI to Improve Evidence-Based Policies." Pp. 57–64 in *2021 IEEE 23rd Conference on Business Informatics (CBI)*. Bolzano, Italy: IEEE.
- Cerqueira, Vitor, Luis Torgo, and Igor Mozetič. 2020. "Evaluating Time Series Forecasting Models: An Empirical Study on Performance Estimation Methods." *Machine Learning* 109(11):1997–2028. doi:10.1007/s10994-020-05910-7.
- Christoph Molnar. 2025. *Interpretable Machine Learning: A Guide for Making Black Box Models Explainable (3rd Ed.)*. 3rd ed. <https://christophm.github.io/interpretable-ml-book/>.
- Cohen, Wesley M., and Daniel A. Levinthal. 1990. "Absorptive Capacity: A New Perspective on Learning and Innovation." *Administrative Science Quarterly* 35(1):128. doi:10.2307/2393553.
- Davydenko, Andrey, and Robert Fildes. 2014. "Measuring Forecasting Accuracy: Problems and Recommendations (by the Example of SKU-Level Judgmental Adjustments)." Pp. 43–70 in *Intelligent Fashion Forecasting Systems: Models and Applications*, edited by T.-M. Choi, C.-L. Hui, and Y. Yu. Berlin, Heidelberg: Springer Berlin Heidelberg.
- Djaballah, Said, Lotfi Saidi, Kamel Meftah, Abdelmoumene Hechifa, Mohit Bajaj, and Ievgen Zaitsev. 2024. "A Hybrid LSTM Random Forest Model with Grey Wolf Optimization for Enhanced Detection of Multiple Bearing Faults." *Scientific Reports* 14(1):23997. doi:10.1038/s41598-024-75174-x.
- Geng, Shukun. 2024. "Analysis of the Different Statistical Metrics in Machine Learning." *Highlights in Science, Engineering and Technology* 88:350–56. doi:10.54097/jhq3tv19.

- Gopal Krushna Panda. 2024. "Sustainable Finance: Driving a Greener Future." *International Journal For Multidisciplinary Research* 6(3):21066. doi:10.36948/ijfmr.2024.v06i03.21066.
- Gur, Yunus Emre. 2024. "Development and Application of Machine Learning Models in US Consumer Price Index Forecasting: Analysis of a Hybrid Approach." *Data Science in Finance and Economics* 4(4):469–513. doi:10.3934/DSFE.2024020.
- Hekkert, Marko P., Matthijs J. Janssen, Joeri H. Wesseling, and Simona O. Negro. 2020. "Mission-Oriented Innovation Systems." *Environmental Innovation and Societal Transitions* 34:76–79. doi:10.1016/j.eist.2019.11.011.
- Hong, Yong-Bum, and Jong-Du Choi. 2023. "Prediction of KOSPI Index by Time Series Based on Convergence Model Using Cross-Validation of Time Series Data." *Journal of the Korean Operations Research and Management Science Society* 48(4):1–21. doi:10.7737/JKORMS.2023.48.4.001.
- Hu, Rongzan, and Qinghua Liu. 2024. "Active Noise Control System Based on the Combined CNN-LSTM Network." P. 15 in *Workshop on Electronics Communication Engineering (WECE 2023)*, edited by W. Xu. Guilin, China: SPIE.
- Katz, Yaron. 2021. "Government's Role in Advancing Innovation." *Randwick International of Social Science Journal* 2(2):161–75. doi:10.47175/rissj.v2i2.236.
- Kervanci, I. sibel, and Fatih Akay. 2023. "LSTM Hyperparameters Optimization with Hparam Parameters for Bitcoin Price Prediction." *Sakarya University Journal of Computer and Information Sciences* 6(1):1–9. doi:10.35377/saucis...1172027.
- Konstantinov, Andrei, Lev Utkin, and Stanislav Kirpichenko. 2022. "AGBoost: Attention-Based Modification of Gradient Boosting Machine." Pp. 96–101 in *2022 31st Conference of Open Innovations Association (FRUCT)*. Helsinki, Finland: IEEE.
- Kumar, Bhupendra, Sunil, and Neha Yadav. 2023. "A Novel Hybrid Model Combining β S A R M A and LSTM for Time Series Forecasting." *Applied Soft Computing* 134:110019. doi:10.1016/j.asoc.2023.110019.
- Lundberg, Scott M., Gabriel Erion, Hugh Chen, Alex DeGrave, Jordan M. Prutkin, Bala Nair, Ronit Katz, Jonathan Himmelfarb, Nisha Bansal, and Su-In Lee. 2020. "From Local Explanations to Global Understanding with Explainable AI for Trees." *Nature Machine Intelligence* 2(1):56–67. doi:10.1038/s42256-019-0138-9.

- Monte dei Paschi, and Camillo Giliberto. 2024. "Sustainable Investments and ESG Factors." *RISK MANAGEMENT MAGAZINE* 19(3):44–52. doi:10.47473/2020rmm0147.
- OECD. 2024. *Designing Effective Governance to Enable Mission Success*. 168th ed. *OECD Science, Technology and Industry Policy Papers*. OECD Science, Technology and Industry Policy Papers. doi:10.1787/898bca89-en.
- Pahuja, Lavina, and Ahmad Kamal. 2023. "ENLEFD-DM : Ensemble Learning Based Ethereum Fraud Detection Using CRISP-DM Framework." *Expert Systems* 40(9):e13379. doi:10.1111/exsy.13379.
- Rob J Hyndman and George Athanasopoulos. 2025. *Forecasting: Principles and Practice (3rd Ed)*. 3rd ed.
- Sergeev, Aleksandr, Elena Baglaeva, and Irina Subbotina. 2024. "Hybrid Model Combining LSTM with Discrete Wavelet Transformation to Predict Surface Methane Concentration in the Arctic Island Belyy." *Atmospheric Environment* 317:120210. doi:10.1016/j.atmosenv.2023.120210.
- WIPO. 2024. "Global Innovation Index." <https://prosperitydata360.worldbank.org/en/dataset/WIPO+GII>. <https://www.wipo.int/en/web/global-innovation-index>.
- Yang, Tianbo, Shiyang He, Xiaojiao Chen, Peng Fu, Liansheng Huang, and Xiuqing Zhang. 2024. "Combined Multi-Component Composite Time Series Power Prediction Model for Distributed Energy Systems Based on Stl Data Decomposition."
- Zainuddin, Aznilinda, Muhammad Asraf Hairuddin, Ahmad Ihsan Mohd Yassin, Zatul Iffah Abd Latiff, and Aziemah Azhar. 2022. "Time Series Data and Recent Imputation Techniques for Missing Data: A Review." Pp. 346–50 in *2022 International Conference on Green Energy, Computing and Sustainable Technology (GECOST)*. Miri Sarawak, Malaysia: IEEE.
- Zhang, Weiqian, Songsong Li, Zhichang Guo, and Yizhe Yang. 2023. "A Hybrid Forecasting Model Based on Deep Learning Feature Extraction and Statistical Arbitrage Methods for Stock Trading Strategies." *Journal of Forecasting* 42(7):1729–49. doi:10.1002/for.2978.