

BAB I

PENDAHULUAN

1.1 Latar Belakang

Perkembangan deep learning telah memperluas pendekatan yang digunakan dalam prediksi pasar saham. Model deep learning menggunakan jaringan saraf berlapis untuk mempelajari hubungan yang kompleks dan nonlinier antara fitur masukan dan target prediksi. Jiang (2021) menunjukkan bahwa penerapan deep learning dalam prediksi pasar saham telah berkembang melalui penggunaan berbagai sumber data, struktur jaringan, dan metrik evaluasi. Namun, kajian tersebut juga menegaskan bahwa prediksi pasar saham tetap menjadi permasalahan yang menantang. Kondisi ini menunjukkan bahwa perkembangan arsitektur model belum sepenuhnya menyelesaikan persoalan prediksi data keuangan.

Kesulitan prediksi saham berkaitan dengan karakteristik data harga yang kompleks, bising, nonlinier, dan berubah mengikuti kondisi pasar. Ji et al. (2022) menjelaskan bahwa harga saham dipengaruhi oleh kebijakan, lingkungan pasar, dan sentimen, sedangkan data yang dihasilkan memiliki tingkat gangguan yang tinggi. Bao, Yue, dan Rao (2017) juga menyatakan bahwa prediksi pasar saham merupakan salah satu persoalan deret waktu yang sulit karena volatilitas dan gangguan pada data keuangan. Karakteristik tersebut menyebabkan pola yang terbentuk pada suatu periode belum tentu berulang secara identik pada periode berikutnya. Oleh karena itu, penggunaan model yang lebih

kompleks tidak secara otomatis menghasilkan kesalahan prediksi yang lebih rendah.

Salah satu implementasi jaringan saraf yang dapat digunakan untuk pemodelan prediktif adalah H2O Deep Learning. Berdasarkan dokumentasi resminya, H2O Deep Learning merupakan jaringan saraf tiruan *feed-forward* berlapis yang dilatih menggunakan *stochastic gradient descent* dan *back-propagation*. Arsitektur tersebut sesuai untuk data tabular yang telah disusun menjadi sekumpulan fitur masukan. Berbeda dari jaringan saraf berulang yang secara intrinsik memproses urutan, H2O Deep Learning memerlukan representasi temporal yang dibentuk secara eksplisit ketika diterapkan pada data deret waktu. Dalam penelitian ini, hubungan temporal direpresentasikan melalui fitur *lag*, sedangkan harga penutupan pada waktu $t + 1$ ditetapkan sebagai variabel target. Dengan demikian, H2O Deep Learning digunakan sebagai model berbasis fitur untuk mempelajari hubungan nonlinier antara data historis dan harga penutupan satu periode perdagangan berikutnya.

Kinerja H2O Deep Learning tidak hanya ditentukan oleh struktur jaringan, tetapi juga oleh kualitas fitur yang diberikan kepada model. Htun, Biehl, dan Petkov (2023) menunjukkan bahwa pemilihan dan ekstraksi fitur merupakan tahap penting dalam prediksi pasar saham karena fitur yang digunakan memengaruhi kemampuan model dalam mengidentifikasi informasi yang relevan. Ji et al. (2022) juga menunjukkan bahwa penggunaan indikator dalam jumlah besar tanpa evaluasi kualitas dapat menghasilkan informasi yang redundan dan meningkatkan kompleksitas pemodelan. Oleh karena itu, penambahan fitur tidak seharusnya diasumsikan selalu

meningkatkan kinerja. Kontribusi setiap fitur perlu diuji menggunakan konfigurasi model dan prosedur evaluasi yang konsisten.

Data *open*, *high*, *low*, dan *close* atau OHLC digunakan sebagai skenario OHLC dalam penelitian ini. Keempat komponen tersebut merepresentasikan rentang pergerakan harga selama satu periode perdagangan. Namun, OHLC belum secara eksplisit merangkum dimensi momentum, perubahan tren, dan volatilitas. Oleh karena itu, model juga diuji menggunakan Relative Strength Index atau RSI, Moving Average Convergence Divergence atau MACD, serta Bollinger Bands. RSI digunakan sebagai representasi momentum harga, MACD sebagai representasi perubahan tren dan momentum, sedangkan Bollinger Bands sebagai representasi volatilitas dan posisi relatif harga. Mostafavi dan Hooman (2025) mengelompokkan indikator teknikal berdasarkan informasi momentum, tren, volatilitas, dan volume. Penelitian tersebut juga menegaskan bahwa belum terdapat konsensus mengenai kumpulan indikator teknikal yang paling sesuai untuk setiap model prediksi.

Ketidakpastian dan struktur nonlinier dalam data keuangan juga mendorong penggunaan fitur berbasis kompleksitas. Shternshis, Mazzarisi, dan Marmi (2022) menunjukkan bahwa Shannon entropy pada return yang didiskretisasi dapat digunakan untuk mengukur keteraturan dan efisiensi dalam dinamika pasar. Gidea dan Katz (2018) menunjukkan bahwa *topological data analysis* dapat mengidentifikasi pola topologis yang tidak direpresentasikan secara langsung oleh ukuran statistik konvensional. Selanjutnya, de Jesus Jr., Fernández-Navarro, dan Carbonero-Ruz (2025) menunjukkan bahwa fitur turunan TDA, termasuk entropy dan karakteristik persistence diagram, dapat menyediakan informasi tambahan bagi model

prediksi deret waktu keuangan. Berdasarkan landasan tersebut, Entropy Divergence dan Prometheus Topological Persistent Entropy dalam penelitian ini diposisikan sebagai fitur berbasis kompleksitas. Keduanya digunakan untuk menguji apakah representasi ketidakpastian dan struktur topologis memberikan informasi prediktif tambahan di luar OHLC dan indikator teknikal klasik.

Penerapan H2O Deep Learning pada data saham telah dilakukan oleh Naik dan Mohan (2020). Penelitian tersebut menggunakan kombinasi data candlestick dan indikator teknikal sebagai masukan H2O Deep Learning untuk mengklasifikasikan arah pergerakan saham intraday di National Stock Exchange India. Hasilnya menunjukkan bahwa H2O Deep Learning dapat diterapkan pada data harga dan indikator teknikal. Namun, penelitian tersebut berfokus pada klasifikasi arah harga dalam satu pasar dan tidak mengevaluasi kontribusi setiap kelompok indikator secara terpisah terhadap prediksi numerik harga penutupan. Perbedaan ini membuka ruang untuk mengevaluasi H2O Deep Learning dalam kerangka regresi dengan konfigurasi model yang sama, tetapi menggunakan skenario fitur dan objek saham yang berbeda.

Selain membandingkan skenario fitur dalam H2O Deep Learning, penelitian ini menggunakan Autoregressive Integrated Moving Average atau ARIMA sebagai model baseline. ARIMA merupakan pendekatan statistik yang memodelkan hubungan temporal berdasarkan nilai masa lalu dan komponen kesalahan. Ariyo, Adewumi, dan Ayo (2014) menunjukkan bahwa ARIMA dapat diterapkan untuk membangun model prediksi harga saham. Adebiyi, Adewumi, dan Ayo (2014) juga membandingkan ARIMA dengan

jaringan saraf untuk menilai perbedaan kinerja pendekatan statistik dan pendekatan berbasis pembelajaran. Dalam penelitian berbasis *deep learning*, Bao, Yue, dan Rao (2017) menggunakan model statistik sebagai pembanding untuk menilai manfaat tambahan dari model yang lebih kompleks. Dengan demikian, ARIMA digunakan untuk menguji apakah kompleksitas H2O Deep Learning menghasilkan kesalahan prediksi yang lebih rendah daripada pendekatan statistik konvensional, bukan untuk mengasumsikan bahwa salah satu model selalu lebih unggul.

Permasalahan prediksi tersebut kemudian diterapkan pada saham perusahaan telekomunikasi di Asia Tenggara. Sektor telekomunikasi relevan karena menyediakan konektivitas dan infrastruktur yang mendukung aktivitas digital. Suranto et al. (2026) menunjukkan bahwa perkembangan digitalisasi di Asia Tenggara berkaitan dengan infrastruktur, ekonomi digital, tata kelola, dan kondisi sosial yang berbeda di antara negara-negara ASEAN. Perbedaan tersebut menunjukkan bahwa kawasan Asia Tenggara bukan lingkungan pasar yang homogen. Oleh karena itu, saham perusahaan dalam sektor yang sama dapat menghadapi kondisi ekonomi, regulasi, kompetisi, dan perilaku pasar yang berbeda.

Perbedaan konteks nasional juga tercermin dalam karakteristik pasar modal. Thampanya et al. (2020) menemukan bahwa faktor fundamental lebih dominan dalam memengaruhi volatilitas pasar saham di Malaysia dan Thailand, sedangkan faktor perilaku memiliki pengaruh yang lebih besar di Indonesia dan Filipina. Temuan tersebut menunjukkan bahwa model dan fitur yang efektif pada satu pasar belum tentu menghasilkan kinerja yang sama pada pasar lain. Dalam konteks penelitian ini, perbandingan lintas negara

digunakan untuk menguji apakah kontribusi OHLC, indikator teknikal klasik, dan fitur berbasis kompleksitas bersifat konsisten atau spesifik terhadap setiap saham. Dengan demikian, tujuan prediksi tidak hanya menghasilkan nilai harga penutupan, tetapi juga mengevaluasi ketahanan skenario fitur ketika diterapkan pada lingkungan pasar yang berbeda.

Empat saham dipilih secara purposif, yaitu PT Telekomunikasi Indonesia Tbk atau TLKM dari Indonesia, Axiata Group Berhad atau AXIATA dari Malaysia, Advanced Info Service Public Company Limited atau ADVANC dari Thailand, serta PLDT Inc. atau TEL dari Filipina. Pemilihan tersebut didasarkan pada empat pertimbangan. Pertama, setiap perusahaan bergerak dalam sektor telekomunikasi dan tercatat pada bursa saham di negaranya. Kedua, setiap perusahaan memiliki skala operasional yang besar dalam konteks pasar masing-masing. Ketiga, data harga harian tersedia secara berkelanjutan untuk periode penelitian. Keempat, penggunaan satu saham dari setiap negara mengurangi dominasi satu pasar dalam desain perbandingan. Laporan perusahaan menunjukkan bahwa Telkomsel memiliki 159,4 juta pelanggan seluler pada akhir 2024, Axiata melayani lebih dari 175 juta pelanggan pada wilayah operasinya, dan AIS mempertahankan posisi sebagai operator seluler utama Thailand dengan 44,6 juta pelanggan serta pangsa pasar pendapatan sebesar 49% pada akhir 2023. Informasi tersebut mendukung relevansi operasional saham yang dipilih, tetapi keempat saham tidak diklaim sebagai sampel statistik yang mewakili seluruh perusahaan telekomunikasi di Asia Tenggara.

Penggunaan satu perusahaan dari setiap negara juga memberikan fungsi metodologis. Seluruh saham berasal dari sektor yang sama, tetapi

diperdagangkan dalam mata uang, kalender bursa, struktur pasar, dan lingkungan nasional yang berbeda. Desain tersebut memungkinkan penelitian mempertahankan kesamaan sektor sekaligus memperoleh variasi konteks pasar. Perbandingan tidak dilakukan berdasarkan besar RMSE secara langsung antarnegara karena setiap saham memiliki skala harga dan satuan mata uang yang berbeda. Sebaliknya, kinerja skenario fitur dan model dibandingkan dalam saham yang sama. Pendekatan ini mencegah kesimpulan yang keliru akibat membandingkan nilai RMSE mentah dari skala harga yang tidak setara.

Data yang digunakan mencakup data harian periode 2015 sampai 2025. Periode tersebut memberikan jumlah observasi yang memadai untuk membentuk data pelatihan dan data pengujian serta mencakup kondisi pasar yang bervariasi. Data dibagi secara kronologis menjadi 80% observasi awal sebagai data pelatihan dan 20% observasi akhir sebagai data pengujian. Pembagian tidak dilakukan secara acak karena urutan waktu harus dipertahankan dan data dari masa depan tidak boleh masuk ke proses pelatihan. Setiap saham juga menggunakan fitur *lag* yang dipilih berdasarkan struktur historisnya karena hasil analisis menunjukkan bahwa pola ketergantungan temporal tidak sama untuk seluruh saham.

Urgensi penelitian terletak pada belum jelasnya manfaat penambahan indikator terhadap data OHLC. Penggunaan indikator teknikal dalam prediksi saham telah menjadi praktik umum, tetapi tidak terdapat kesepakatan bahwa indikator tertentu akan selalu meningkatkan kinerja pada setiap saham dan model. Indikator yang diturunkan dari sumber harga yang sama dapat menghasilkan informasi tambahan, informasi redundan, atau gangguan,

bergantung pada karakteristik data. Penggunaan indikator tanpa evaluasi dapat meningkatkan jumlah fitur dan kompleksitas model tanpa menjamin penurunan kesalahan prediksi. Permasalahan tersebut menjadi lebih relevan ketika model diterapkan pada saham dari pasar nasional yang berbeda karena hubungan antara fitur dan target dapat bersifat spesifik terhadap setiap saham.

Berdasarkan literatur yang ditinjau, penelitian mengenai prediksi saham telah menggunakan data OHLC, indikator teknikal, pendekatan berbasis entropi, TDA, dan berbagai model *deep learning*. Namun, penelitian yang secara terkontrol membandingkan kontribusi indikator teknikal klasik dan fitur berbasis kompleksitas menggunakan konfigurasi H2O Deep Learning yang sama pada saham perusahaan telekomunikasi di beberapa negara ASEAN masih terbatas. Penelitian terdahulu menggunakan H2O Deep Learning untuk klasifikasi saham di satu pasar, sedangkan penelitian TDA dan entropy umumnya menggunakan model, aset, atau tujuan analisis yang berbeda. Oleh karena itu, kesenjangan penelitian tidak terletak pada ketiadaan penggunaan *deep learning* atau indikator teknikal, tetapi pada terbatasnya evaluasi terpisah terhadap kontribusi setiap skenario fitur dalam konteks lintas pasar yang sebanding.

Penelitian ini mengevaluasi enam skenario fitur, yaitu OHLC, OHLC + RSI, OHLC + MACD, OHLC + Bollinger Bands, OHLC + Entropy Divergence, serta OHLC + Prometheus Topological Persistent Entropy. OHLC digunakan sebagai baseline fitur, sedangkan lima skenario lainnya digunakan untuk mengukur perubahan kinerja setelah penambahan satu kelompok fitur. Seluruh skenario dijalankan menggunakan konfigurasi H2O Deep Learning yang sama agar perbedaan hasil terutama mencerminkan

perbedaan skenario fitur dan karakteristik saham. Skenario H2O Deep Learning dengan rata-rata RMSE terendah pada setiap saham kemudian dibandingkan dengan ARIMA sebagai model baseline.

Kebaruan penelitian ini terletak pada evaluasi komparatif enam skenario fitur dalam kerangka H2O Deep Learning yang konsisten pada empat saham perusahaan telekomunikasi dari pasar Asia Tenggara yang berbeda. Penelitian ini tidak mengklaim bahwa H2O Deep Learning merupakan metode baru atau selalu lebih unggul daripada model lain. Kontribusi penelitian terletak pada pengujian apakah indikator momentum, tren, volatilitas, entropy, dan kompleksitas topologis menghasilkan kontribusi yang konsisten atau spesifik terhadap setiap saham. Penelitian ini bertujuan menentukan skenario fitur dengan kesalahan prediksi terendah pada setiap saham, menilai manfaat penambahan fitur dibandingkan OHLC, serta membandingkan kinerja skenario H2O Deep Learning terbaik dengan ARIMA. Hasil penelitian diharapkan memberikan dasar empiris bagi pengembangan model prediksi berbasis fitur dalam konteks analitik dan sistem pendukung keputusan, bukan sebagai rekomendasi langsung untuk melakukan transaksi saham.

1.2 Rumusan Masalah

1. Bagaimana kinerja model H2O Deep Learning dalam memprediksi harga penutupan saham telekomunikasi di Asia Tenggara berdasarkan nilai RMSE?
2. Bagaimana perbandingan kinerja model H2O Deep Learning dengan ARIMA sebagai model baseline dalam memprediksi harga penutupan saham telekomunikasi di Asia Tenggara?

3. Sejauh mana skenario fitur berbasis OHLC dan indikator tambahan, yaitu RSI, MACD, Bollinger Bands, Entropy Divergence, dan Prometheus Topological Persistent Entropy, dapat menurunkan error prediksi dibandingkan penggunaan Skenario OHLC?
4. Bagaimana perbedaan skenario fitur terbaik dan kinerja model pada masing-masing saham telekomunikasi yang mewakili Indonesia, Malaysia, Thailand, dan Filipina?

1.3 Tujuan

1. Mengevaluasi kinerja model H2O Deep Learning dalam memprediksi harga penutupan saham telekomunikasi di Asia Tenggara berdasarkan nilai RMSE.
2. Membandingkan kinerja model H2O Deep Learning dengan ARIMA sebagai model baseline pada setiap saham telekomunikasi yang diteliti.
3. Mengukur kontribusi setiap skenario fitur, yaitu Skenario OHLC, OHLC + RSI, OHLC + MACD, OHLC + Bollinger Bands, OHLC + Entropy Divergence, dan OHLC + Prometheus Topological Persistent Entropy, terhadap penurunan error prediksi.
4. Mengidentifikasi skenario fitur terbaik dan membandingkan kinerja model pada saham TLKM Indonesia, AXIATA Malaysia, ADVANC Thailand, dan TEL Filipina.

1.4 Batasan Penelitian

1. Data yang digunakan terbatas pada harga historis harian (OHLC) dan indikator teknikal turunan dari periode 1 Januari 2015 hingga 31 Desember 2025. Fitur masukan meliputi *Open*, *High*, *Low*, dan *Close*

(OHLC), bersama dengan indikator seperti RSI, MACD, *Bollinger Bands*, *Entropy Divergence*, dan *Prometheus Topological Persistent Entropy*.