

Prediksi Harga Saham PT Bank Rakyat Indonesia Tbk Menggunakan AUTOML H2O

I Made Tirta, Abduh Riski, dan Nining Sholikhah

Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Jember

Jl. Kalimantan No. 37, Jember 68121, Jawa Timur

E-mail: itirta.fmipa@unej.ac.id , riski.fmipa@unej.ac.id, 201810101090@mail.unej.ac.id

Abstrak

Bank BRI merupakan perusahaan milik Pemerintah dengan harga saham yang tercatat pada *Initial Public Offering* (IPO) yang berstatus sebagai perusahaan publik. Harga saham Bank BRI mengalami fluktuasi yang disebabkan oleh beberapa faktor. Memprediksi harga saham Bank BRI menjadi hal yang penting untuk memudahkan investor dalam mengambil keputusan investasi. *Auto Machine Learning* (AutoML) mengacu pada konsep pelatihan *machine learning* dan *tuning parameter* secara otomatis. H2OAutoML dapat digunakan untuk memprediksi harga saham dengan menyederhanakan kode program dan mempercepat pengembangan algoritma yang akurat. H2OAutoML menyediakan berbagai algoritma, namun yang digunakan dalam penelitian ini adalah *Generalized Linear Model* (GLM), *Distributed Random Forest* (DRF), *Gradient Boosting Machine* (GBM), dan *stacked ensemble*. Tujuan dari penelitian ini adalah untuk mengetahui algoritma optimal dan hasil prediksi yang dihasilkan oleh H2OAutoML pada harga saham *close*. Algoritma dasar terbaik menurut H2OAutoML adalah GBM dengan nilai MAPE terkecil dan *R Square* terbesar. Namun, ketika algoritma dasar tersebut digabungkan dengan teknik *stacking* menghasilkan prediksi yang lebih baik. Algoritma dasar yang digunakan untuk membangun *stacked ensemble* adalah DRF, XRT, GLM, dan GBM. *Stacked ensemble* ini dibangun secara otomatis oleh H2OAutoML dengan algoritma *metalearning* GLM. Dengan demikian *stacked ensemble* mampu memprediksi dengan akurasi yang cukup baik dan dapat menjelaskan variabilitas data.

Kata kunci: Harga Saham, AutoML, H2O, dan *Stacked Ensemble*

Pendahuluan

Saham merupakan surat yang menunjukkan kepemilikan dengan nilai nominal, serta hak dan kewajiban bagi pemegang saham [1]. Harga saham yang tercatat dalam IPO menjadi perusahaan publik, salah satunya PT Bank Rakyat Indonesia Tbk (Bank BRI). Bank BRI melakukan IPO pada 10 November 2003 dengan harga yang ditetapkan sebesar IDR 875 per lembar [2]. Harga saham Bank BRI bersifat fluktuatif yang disebabkan oleh beberapa faktor seperti faktor internal dan faktor eksternal.

Pergerakan harga saham dapat diprediksi dengan *machine learning* seperti *Distributed Random Forest* (DRF), *Generalized Linear Model* (GLM), dan *Gradient Boosting Machine* (GBM). *Machine learning* dapat meningkatkan efisiensi proses pengambilan keputusan dengan wawasan prediktif secara otomatis. Belakangan ini telah dikembangkan *Auto Machine Learning* (AutoML) untuk memudahkan praktisi dalam mengembangkan algoritma secara otomatis. AutoML merujuk pada

konsep pelatihan *machine learning* dan *tuning parameter* secara otomatis dalam batas waktu yang ditentukan. Salah satu fitur AutoML disediakan oleh H2O dengan *library open source* yang dikembangkan oleh perusahaan H2O.ai bernama H2OAutoML.

Beberapa penelitian mengenai H2OAutoML untuk memprediksi harga *bitcoin* menghasilkan 10 algoritma terbaik. Algoritma yang digunakan mencakup DRF, GBM, *Extra Gradient Boosting* (XGBoost), dan *stacked ensemble*. Algoritma terbaik yang dihasilkan oleh H2OAutoML adalah *stacked ensemble* dengan nilai *R Square* sebesar 0,968 dan nilai *Mean Absolute Percentage Error* (MAPE) 3,48% terhadap data pengujian [3].

Penelitian lainnya dalam memprediksi tingkat kematian pasien akibat infeksi COVID-19 selama sebulan di *Clinical Looking Glass*. Algoritma yang digunakan adalah DRF, GBM, XGBoost, dan *stacked ensemble*. Penelitian ini mengidentifikasi kasus klasifikasi dan mendapatkan *variable importance* terbesar adalah tekanan sistolik dengan pre-

sentase 0,206. *Deep learning* pada penelitian ini dikecualikan karena tidak dapat direproduksi secara default oleh H2OAutoML [4].

Penelitian terdahulu dalam memprediksi perambatan retak pada material *Acrylonitrile Butadiene Styrene* (ABS) menggunakan H2O AutoML mendapatkan algoritma terbaik adalah GBM. Nilai *deviance* nya sebesar 0,061 dengan *variable importance* nya adalah frekuensi alami. Base model yang digunakan 3 dan didapatkan base modelnya adalah GLM, GBM, dan DRF [5].

Penelitian ini bertujuan untuk memprediksi harga *close* saham harian Bank BRI menggunakan H2OAutoML. Algoritma yang digunakan adalah DRF, GBM, GLM, dan *stacked ensemble* dengan waktu 600 detik. Penelitian ini menggunakan regresi time series *Vector Autoregressive Exogenous* (VARX). Berdasarkan uraian diatas peneliti ingin mengetahui algoritma dan hasil prediksi terbaik pada harga *close* pada waktu ke- *t* pada saham harian Bank BRI menggunakan H2OAutoML.

Harga saham mencerminkan nilai saham yang diperdagangkan, menggambarkan profitabilitas perusahaan pada waktu tertentu, dan berubah sesuai dengan permintaan dan penawaran. Harga saham di BEI dalam *candle stick* mencakup harga *open*, *high*, *low*, dan *close* [6]. Harga saham dapat dipengarauhi oleh beberapa faktor tetapi harga saham dapat dilakukan prediksi berdasarkan data historis menggunakan metode regresi *time series*.

Model VARX adalah pengembangan model *Vector Autoregressive* (VAR) yang menggunakan variabel eksogen dalam persamaannya [7]. Persamaan dibawah ini menunjukkan persamaan model VARX.

$$z_t = \alpha + \phi_1 z_{t-1} + \dots + \phi_p z_{t-p} + \theta_1 x_{t-1} + \dots + \theta_p x_{t-p} + \varepsilon_t \quad (1)$$

Machine learning merupakan bagian dari *Artificial Intellegence* (AI) yang berfokus untuk pembuatan algoritma yang dipelajari. Ada 3 jenis *machine learning* yaitu *unsupervised learning*, *reinforcement learning*, dan *supervised learning*. H2OAutoML hanya dapat menangani *supervised learning* yang memungkinkan proses pembelajaran secara otomatis sehingga mempercepat pengembangan algoritma prediktif. Proses otomatisasi pada H2OAutoML adalah algoritma *selection*, algoritma pelatihan, *tuning hyperparameter*, dan prediksi.

GLM menunjuk pada metode regresi yang khusus untuk jenis distribusi probabilitas data. H2OAutoML memilih secara otomatis jenis distribusi saat melatih algoritma GLM. Data saham memiliki tipe data numerik sehingga distribusi yang digunakan adalah distribusi normal. Estimasi parameter *likelihood* pada distribusi normal digunakan untuk memperoleh penaksir parameter dengan memaksimalkan fungsi *log likelihood*. Algoritma GLM mempunyai teknik untuk menghindari *overfitting* den-

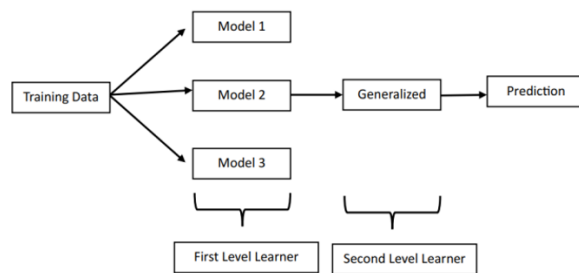
gan regularisasi penalti seperti regresi *ridge*, regresi LASSO, dan regresi *elastic-net*. Jadi GLM di H2O menyesuaikan algoritmanya dengan memaksimalkan *Log Likelihood* dikurangi dengan regularisasi *penalty* [8].

DRF pada H2OAutoML mencakup DRF dan XRT, DRF sama seperti *random forest* yaitu algoritma *ensemble bagging* yang menggunakan *decision tree*. XRT membangun *ensemble* dari *decision tree* berdasarkan pendekatan *top-down* yang sederhana menggunakan seluruh sampel dan memilih titik pemotongan acak untuk setiap fitur yang dipertimbangkan. *Extra Tree* menghasilkan prediksi dengan menggabungkan hasil dari setiap *decision tree* dengan cara rata-rata [9].

GBM merupakan algoritma *machine learning* yang merupakan *ensemble boosting* dari *decision tree*. Algoritma GBM bekerja secara berurutan dengan menambahkan *decision tree* sebelumnya yang kurang akurat dalam memprediksi [10]. GBM memulai dengan menghasilkan pohon awal dan terus menyesuaikan pohon baru melalui fungsi kerugian sesuai dengan persamaan dibawah ini.

$$residu\ semu = z_i - \hat{z}_i \quad (2)$$

Stacked ensemble merupakan sebuah teknik *machine learning* yang melibatkan penggabungan beberapa algoritma. *Stacked ensemble* dibangun secara otomatis oleh H2OAutoML berdasarkan algoritma dasar yang digunakan. Algoritma akan digabungkan oleh algoritma kedua yang dipilih secara otomatis oleh H2OAutoML. Gambar 1 menunjukkan metode *stacked ensemble* [12].



Gambar 1: Metode *Stacked Ensemble*

Pengukuran kesalahan algoritma dengan cara evaluasi algoritma untuk melihat kinerja algoritma. Kualitas prediksi dapat diukur dengan pengukuran nilai *error*.

1. *Deviance*

$$D = \sum_{i=1}^n ((y_i - \hat{y}_i)^2) \quad (3)$$

2. Koefisien Determinasi

$$R^2 = 1 - \frac{\sum(y_i - \hat{y}_i)^2}{\sum(y_i - \bar{y})^2} \quad (4)$$

3. Mean Absolute Percentage Error

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i} \times 100\% \quad (5)$$

Metode Penelitian

Penelitian dimulai dengan memilih topik dan melakukan tinjauan pustaka dari berbagai referensi yang relevan. Data yang akan diteliti diambil dan diolah menggunakan *Google Colab*. Tahapan pada penelitian ini adalah *load dataset*, *preprocessing data*, dan otomatisasi AutoML dari H2O.

Load Dataset

Tahap *load dataset* merupakan tahap memasukkan data yang dilakukan di *Google Colab*. Proses ini perlu meng-*import* modul *pandas*, modul *matplotlib*, modul *numpy*, dan modul *scipy.stats*. Data yang digunakan sebelumnya tersimpan dalam *google drive* sehingga harus menggunakan modul *drive*. Modul *drive* digunakan untuk mengakses data yang tersimpan dalam *google drive*.

Preprocessing Data

Tahap *preprocessing data* merupakan tahap mengolah data mentah agar menjadi data yang siap untuk diolah. *Preprocessing data* meliputi beberapa langkah seperti *cleaning data*, pembentukan variabel *lag*, dan *splitting data*.

Cleaning Data

Cleaning data merupakan tahapan yang penting dalam persiapan data untuk analisis. Data yang digunakan adalah *date*, harga *open*, dan harga *close*. Tahap ini mencakup pengecekan *missing value* untuk mengetahui nilai yang hilang dalam data. Terdapat satu *missing value* pada kolom harga *close* dan *open*. Data yang hilang tersebut terjadi pada tanggal 19 Juni 2019. Penanganan *missing value* menggunakan teknik *mean imputation* pada hari sebelum dan sesudah 19 Juni 2019.


Pembentukan Variabel Lag

Gambar 2 menunjukkan pembentukan variabel *lag* dengan kolom harga *open* dan *close* dengan panjang $p=3$ akan menghasilkan data baru.

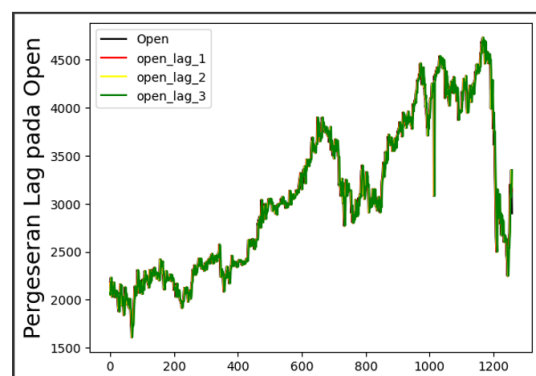
Penanganan *missing value* pada Gambar 2 dilakukan dengan cara dihapus karena untuk mempertahankan urutan nilai dari *lag*nya. Gambar 3 menunjukkan pembentukan variabel *lag* pada kolom *close*. Sedangkan Gambar 4 menunjukkan *lag* pada kolom *open*.

	Date	Open	Close	open_lag_1	open_lag_2	open_lag_3
0	2015-06-15	2070.0	2030.0	NaN	NaN	NaN
1	2015-06-16	2050.0	2110.0	2070.0	NaN	NaN
2	2015-06-17	2130.0	2200.0	2050.0	2070.0	NaN
3	2015-06-18	2180.0	2155.0	2130.0	2050.0	2070.0
4	2015-06-19	2165.0	2210.0	2180.0	2130.0	2050.0
...
1257	2020-06-08	3180.0	3300.0	3070.0	3120.0	3200.0
1258	2020-06-09	3350.0	3210.0	3180.0	3070.0	3120.0
1259	2020-06-10	3180.0	3030.0	3350.0	3180.0	3070.0
1260	2020-06-11	3130.0	2970.0	3180.0	3350.0	3180.0
1261	2020-06-12	2900.0	3030.0	3130.0	3180.0	3350.0
...
	close_lag_1	close_lag_2	close_lag_3			
0	NaN	NaN	NaN			
1	2030.0	NaN	NaN			
2	2110.0	2030.0	NaN			
3	2200.0	2110.0	2030.0			
4	2155.0	2200.0	2110.0			
...			
1257	3110.0	3060.0	3100.0			
1258	3300.0	3110.0	3060.0			
1259	3210.0	3300.0	3110.0			
1260	3030.0	3210.0	3300.0			
1261	2970.0	3030.0	3210.0			

Gambar 2: Pembentukan Variabel Lag




Gambar 3: Lag pada Close



Gambar 4: Lag pada Open

Splitting Data

Splitting data merupakan proses pembagian data menjadi dua bagian yaitu data pelatihan dan data pengujian. Data harga saham harian Bank BRI dibagi dengan perbandingan data pelatihan dan data pengujian adalah sebesar 80 : 20. Data pelatihan sebanyak 1.007 dan data pengujian sebanyak 252. Gambar 5 menunjukkan perbandingan data pelatihan dan data pengujian.



Gambar 5: Perbandingan Data Pelatihan dan Data Pengujian

Otomatisasi AutoML dari H2O

Tahap ini merupakan proses otomatisasi H2OAutoML dengan menginputkan data ke H2O Frame, mendefinisikan objek, dan menemukan algoritma yang optimal berdasarkan H2OAutoML.

Input Data ke H2O

Tahap ini memanggil library H2OAutoML sebelum menginputkan data pelatihan dan data pengujian. Data pelatihan dan data pengujian dimasukkan kedalam H2O Frame karena sebelumnya memiliki format data frame pandas yang tidak bisa secara langsung menjadi input H2OAutoML. Gambar 6 menunjukkan definisi variabel eksogen dan variabel endogen yang digunakan.

Variabel	Simbol	Variabel
Harga Open $t - 1$	x_{t-1}	Variabel eksogen pada waktu sehari sebelum
Harga Open $t - 2$	x_{t-2}	Variabel eksogen pada waktu dua hari sebelum
Harga Open $t - 3$	x_{t-3}	Variabel eksogen pada waktu tiga hari sebelum
Harga Close $t - 1$	z_{t-1}	Variabel endogen pada waktu sehari sebelum
Harga Close $t - 2$	z_{t-2}	Variabel endogen pada waktu dua hari sebelum
Harga Close $t - 3$	z_{t-3}	Variabel endogen pada waktu tiga hari sebelum
Harga Close	z_t	Variabel endogen pada waktu ke t

Gambar 6: Definisi Variabel

Persamaan regresi time series VARX yang terbentuk adalah sebagai berikut.

$$z_t = \alpha + \phi_1 z_{t-1} + \phi_2 z_{t-2} + \phi_3 z_{t-3} + \theta_1 x_{t-1} + \theta_2 x_{t-2} + \theta_3 x_{t-p} + \varepsilon_t \quad (6)$$

Algoritma Terbaik


Algoritma yang dihasilkan oleh H2OAutoML telah disesuaikan parameternya selama proses pelatihan untuk mencapai performa optimal. Semua algoritma ini ditampilkan dalam papan peringkat yang mencakup model ID, nilai RMSE, MSE, MAE, RM-SLE, dan deviance. Papan peringkat mengidentifikasi algoritma optimal berdasarkan nilai deviance

terkecil. H2OAutoML dalam waktu 10 menit mendapatkan 185 algoritma dengan nilai deviance terkecil adalah stacked ensemble sebesar 12,355.

Algoritma GLM pada H2OAutoML dibangun secara otomatis dengan menggabungkan berbagai parameter. Hal ini menciptakan algoritma yang optimal tanpa intervensi manual. Proses cross validation menggunakan 5 fold, dengan fold assignment menggunakan metode modulo. Selama proses cross validation algoritma diuji dengan berbagai kombinasi parameter yaitu alpha dan lambda. Nilai alpha yang dihasilkan adalah 0 yang menunjukkan bahwa regularisasi yang digunakan adalah ridge. Nilai lambda yang paling optimum adalah 0,066 dari 31 nilai lambda yang lainnya. Batas waktu maksimum yang digunakan untuk pelatihan algoritma GLM adalah 239 detik. Berikut adalah persamaan regresi yang terbentuk.

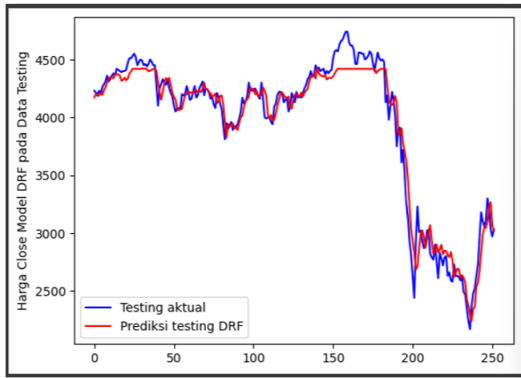
$$z_t = 41,121 + 0,233z_{t-1} + 0,164z_{t-2} + 0,134z_{t-3} + 0,181x_{t-1} + 0,141x_{t-2} + 0,131x_{t-3} \quad (7)$$

Gambar 7 menunjukkan perbandingan data prediksi algoritma GLM dan data aktual pada data pengujian.



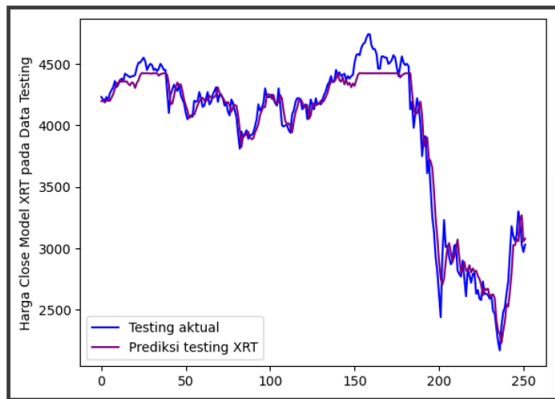
Gambar 7: Perbandingan Data Prediksi Algoritma GLM dan Data Aktual

Algoritma DRF pada H2OAutoML dibangun secara otomatis dengan menggabungkan berbagai parameter. Hal ini menciptakan algoritma yang optimal tanpa intervensi manual. Proses cross validation menggunakan 5 fold, dengan fold assignment menggunakan metode modulo. Algoritma ini membangun sebanyak 37 pohon dengan kedalaman pohon 20. Jumlah bin yang digunakan dalam proses pembentukan pohon sebanyak 20 untuk mengelompokkan nilai-nilai kontinu. Pengambilan sample bootstrap untuk melatih setiap pohon adalah 63,2% dengan pembagian node sebesar 1×10^{-5} . Batas waktu maksimum yang digunakan untuk pelatihan algoritma ini adalah 104 detik. Gambar 8 menunjukkan perbandingan data prediksi algoritma DRF dan data aktual pada data pengujian.



Gambar 8: Perbandingan Data Prediksi Algoritma DRF dan Data Aktual


Algoritma XRT pada H2OAutoML dibangun secara otomatis dengan menggabungkan berbagai parameter. Hal ini menciptakan algoritma yang optimal tanpa intervensi manual. Proses *cross validation* menggunakan 5 fold, dengan *fold assignment* menggunakan metode modulo. Algoritma ini membangun sebanyak 29 pohon dengan kedalaman pohon 20. Algoritma XRT membangun pohon dengan jumlah atribut sebanyak 6. Proses pemisahan pembagian node sebesar 1×10^{-5} . Jika dalam pembagian *node* tidak ada peningkatan sebesar nilai tersebut maka pembagian *node* akan dihentikan. Batas waktu maksimum yang digunakan untuk pelatihan algoritma ini adalah 160 detik. Gambar 9 menunjukkan perbandingan data prediksi algoritma XRT dan data aktual pada data pengujian.



Gambar 9: Perbandingan Data Prediksi Algoritma XRT dan Data Aktual

Algoritma GBM pada H2OAutoML dibangun secara otomatis dengan menggabungkan berbagai parameter. Hal ini menciptakan algoritma yang optimal tanpa intervensi manual. Proses *cross validation* menggunakan 5 fold, dengan *fold assignment* menggunakan metode modulo. Algoritma ini membangun sebanyak 57 pohon dengan kedalaman pohon 11. Algoritma GBM tidak terlalu kompleks namun menghasilkan prediksi yang baik karena proses pembentukan pohon dilakukan dengan pendekatan berurutan sesuai dengan Persamaan 2. Gambar 10

menunjukkan perbandingan data prediksi algoritma GBM dan data aktual pada data pengujian.



Gambar 10: Perbandingan Data Aktual Algoritma GBM dan Data Prediksi

Stacked ensemble merupakan metode gabungan yang menggabungkan algoritma XRT, DRF, GLM, dan GBM. algoritma metalearner yang digunakan adalah GLM karena algoritma GLM mampu menangani kasus overfitting menggunakan teknik regularisasi. Persamaan regresi yang terbentuk adalah sebagai berikut.

$$z_t = \alpha + \beta_0 \hat{z}_t^{GBM} + \beta_1 \hat{z}_t^{XRT} + \beta_2 \hat{z}_t^{DRF} + \beta_3 \hat{z}_t^{GLM} + \epsilon_t \quad (8)$$

Proses *cross validation* menggunakan 5 fold, dengan *fold assignment* menggunakan metode random. Saat melakukan validasi silang algoritma diuji dengan berbagai kombinasi parameter yaitu alpha dan lambda. Nilai alpha yang dihasilkan adalah 0.5 yang menunjukkan bahwa regularisasi yang digunakan adalah elastic-net. Nilai lambda yang paling optimum adalah 874. Nilai lambda yang besar menunjukkan bahwa terdapat pengaruh regularisasi yang kuat sehingga menyebabkan koefisien algoritma diredam. Berikut adalah persamaan regresi yang terbentuk.


$$z_t = -1,922 + 0,924 \hat{z}_t^{GBM} + 0,050 \hat{z}_t^{XRT} + 0,026 \hat{z}_t^{GLM} \quad (9)$$

Batas waktu maksimum yang digunakan untuk pelatihan algoritma GLM adalah 135 detik. Gambar 11 menunjukkan perbandingan data prediksi *stacked ensemble* dan data aktual pada data pengujian.

Evaluasi Seluruh Algoritma

Gambar 12 menunjukkan evaluasi metrik menggunakan MAPE dan *R Square* pada data pengujian. Diperoleh hasil yang paling baik yang dihasilkan oleh H2OAutoML adalah *stacked ensemble*. Sedangkan algoritma dasar yang paling baik adalah al-

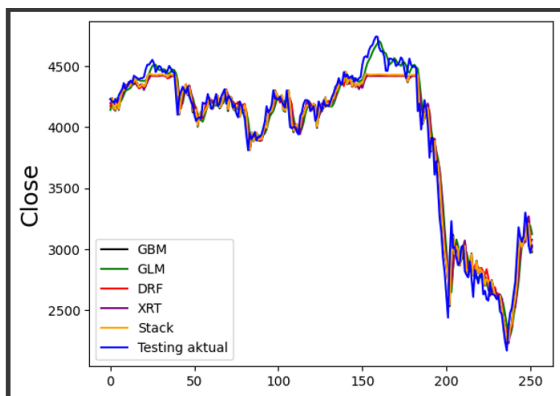
goritma GBM. Gambar 13 menunjukkan visualisasi seluruh algoritma pada data pengujian.



Gambar 11: Perbandingan Data Aktual Stacked Ensemble dan Data Prediksi

Model	MAPE (%)	R Square
GLM	2,474	0,963
DRF	2,571	0,964
XRT	2,479	0,966
GBM	2,327	0,973
<i>Stacked Ensemble</i>	2,299	0,973

Gambar 12: Evaluasi Data Pengujian



Gambar 13: Visualisasi Data Pengujian

Penutup

Algoritma dan hasil prediksi terbaik dalam memprediksi harga close pada waktu ke- t pada algoritma dasar H2OAutoML adalah GBM. MAPE dan R Kuadrat algoritma GBM adalah 2,327 dan 0,973. Namun ketika algoritma dasar digabungkan dengan teknik *stacking* menghasilkan prediksi yang lebih baik. MAPE dan *R Square* pada *stacked ensemble* adalah 2,299 dan 0,973. Penurunan pada MAPE sebesar 0,028 dan peningkatan pada *R Square* sebesar 1×10^{-4} . *Stacked ensemble* dibangun secara otomatis oleh H2OAutoML dari algoritma GLM, DRF, XRT, dan GBM. Algoritma *metalearning*

yang digunakan dalam *stacked ensemble* dipilih secara otomatis oleh H2OAutoML menggunakan algoritma GLM. Algoritma GLM mampu menangani *overfitting* dengan regularisasi penalti.

Penelitian ini secara eksplisit membatasi algoritma yang digunakan hanya pada algoritma berbasis statistik. Untuk penelitian selanjutnya disarankan menggunakan algoritma lainnya yang tersedia pada H2OAutoML.

Daftar Pustaka

- [1] Ni Luh Dwik Suryachayani Gunadi dan Jose Widyatama, "Perhitungan sebagai Seorang Investor Saham Atas Besaran Pajak yang Harus Dibayarkan kepada Negara", Jurnal Locus Delicti, vol. 2., nomor 1, pp: 13 - 23, 2021.
- [2] Andik Setiawan, Irma Mbae, dan Ratno, "Analisis Volume Foreign Net Inflow terhadap Return Saham Bank Rakyat Indonesia dengan Volume Transaksi sebagai Variabel Moderasi Pasca Satu Tahun Pandemi Covid-19", Jurnal Ilmiah Ekomen, Vol. 22., nomor 1, pp: 16-27, 2022.
- [3] Geadalfa Giyanda dan Siti Saidah, "Auto Machine Learning dengan Menggunakan H2O AutoML untuk Prediksi Harga Bitcoin", Jurnal Ilmiah Komputasi, vol. 20., nomor 2, pp: 189 : 198, 2021.
- [4] Kenji Ikemura, Goldsteain, James Szymanski, Eran Bellin, Lindsay, S., Yukako, Y., Mahmoud, S., Katelyn Stahl, Yukako Yagi, Mahmoud Saada, Katelyn Simone, and Morayma Gil Reyes, " Using Automated-Machine Learning to Predict COVID-19 Patient Survival: Identify Influential Biomarkers", Journal Med Internet Res, vol. 23, nomor 2, pp: 1 - 15, 2020.
- [5] Intisar Omar, Muhammad Khan, Andrew Starr and Khaled Abou Rok Ba, "Automated Prediction of Crack Propagation Using H2O AutoML", Sensors (Basel), vol 23, no 8419, edisi 20, 2023.
- [6] Adi Misykatul Anwar, "Pengaruh Current Ratio (CR), Debt To Equity Ratio (DER), Return on Asset (ROA) terhadap Harga Saham (Studi Kasus pada Perusahaan Sektor Makanan dan Minuman yang Terdaftar di BEI Tahun 2017-2019)", Jurnal Ilmiah Mahasiswa Akuntansi, vol. 1, nomor 2, pp: 146 - 157, 2021.
- [7] Alan Prahutama, Agus Rusgiyono dan Tiani Wahyu Utami, "Pemodelan Vector Autoregressive Exogenous (VARX) pada Nilai Inflasi Terhadap PDRB di Jawa Tengah", Jurnal Statistika, vol. 7, nomor 2, pp: 133 - 137, 2019.

- [8] Nykodym Tomas, Tom Kraljevic, Amy Wang, Wendy Wong, and Thomas Fryda, "Generalized Linear Modeling with H2O (Issue November)", H2O.ai, Amerika, 2016.
- [9] Dani Al Mahkya, Khairil Anwar Notodiputro, and Bagus Sartono, "Extra Trees Method for Stock Price Forecasting With Rolling Origin Accuracy Evaluation", Jurnal Media Statistika, vol. 15, nomor 1, pp: 36 - 47, 2022.
- [10] Cahya Alkahfi, Zein Rizky Santoso, Anwar Fitrianto, dan Sachnaz Desta Oktarin,"Variable Importance Kesehatan dan Pendidikan dalam Pembentukan IPM dengan Algoritme Machine Learning", Jurnal Sains dan Informatika, vol. 8, nomor 2, pp: 77 - 85, 2022.
- [11] Md. Maidul Islam, Tanzina Nasrin Tania, Sharmin Akter, and Kazi Hassan Shakib, "An Improved Heart Disease Prediction Using Stacked Ensemble Method", Lecture Notes of the Institute for Computer Sciences, Social-Informatics and Telecommunications Engineering, 490 LNICST, pp: 84 - 97, 2023.

Halaman ini sengaja dikosongkan.