


Vol 9, No 1 (2023)

Volume 9 No 1

DOI: <https://doi.org/10.26418/jp.v9i1>

TABLE OF CONTENTS



This work is licensed under a [Creative Commons Attribution-NonCommercial-ShareAlike 4.0 International License](https://creativecommons.org/licenses/by-nc-sa/4.0/).
01329381 [View MyStat](#)

OPEN JOURNAL SYSTEMS



Journal Help

USER

Username
 Password
 Remember me

JOURNAL CONTENT

Search

Search Scope
 All

Browse

- [By Issue](#)
- [By Author](#)
- [By Title](#)
- [Other Journals](#)

CURRENT ISSUE



KEYWORDS

[Akurasi Analisis Sentimen Android CNN](#)
[Clustering Data Mining Decision Tree](#)
[Deep Learning K-Means KNN](#)
[Klasifikasi LSTM Machine](#)
[Learning Naive Bayes Naive Bayes](#)
[Prediksi Random Forest SVM Sistem](#)
[Informasi Support Vector Machine TF-IDF](#)

FONT SIZE

Vol 9, No 1 (2023)

Volume 9 No 1

DOI: <https://doi.org/10.26418/jp.v9i1>

Table of Contents

Articles

Optimalisasi Kecepatan Sistem Aliran Fluida Metoda Linear Quadratic Regulator Hilda Hilda	PDF 1 - 6
Data preparation Structure untuk Pemodelan Prediktif Jumlah Peserta Ajar Matakuliah Anggi Perwitasari, Rina Septiriana, Tursina Tursina	PDF 7 - 11
Klasifikasi Jenis Rempah Menggunakan Convolutional Neural Network dan Transfer Learning Alvin Eka Putra, Mohammad Farid Naufal, Vincentius Riandaru Prasetyo	PDF 12 - 18
Sistem Pengendalian Manajemen Organisasi Mahasiswa (Ormawa) pada Perguruan Tinggi dengan Aplikasi Website Hariadi Yutanto, Ellen Theresia Sihotang, Kadek Pranetha Prananjaya, Iqbal Ramadhani Mukhlis	PDF 19 - 29
Perbedaan Tingkat Usability Heuristics Evaluation pada Learning Management System Berdasarkan Latar Belakang Pengguna Farha Ramadhan, Agung Fatwanto	PDF 30 - 43
Reduksi Atribut Menggunakan Chi Square untuk Optimasi Kinerja Metode Decision Tree C4.5 Anirma Kandida Br Ginting, Maya Silvi Lydia, Elviawaty Muisa Zamzami	PDF 44 - 49
Deteksi Malware Ransomware Berdasarkan Panggilan API dengan Metode Ekstraksi Fitur N-gram dan TF-IDF Hartinah Hartinah, Ady Wahyudi Paundu, Amil Ahmad Ilham	PDF 50 - 58
Sistem Kendali Proporsional Kualitas Air berupa Ph dan Suhu pada Budidaya Ikan Lele Berbasis IoT Tri Widodo, Angga Bayu Santoso, Sahriah Ihsani Ishak, Ramli Rumeon	PDF 59 - 66
Perancangan Game Visual Novel sebagai Alat Ukur Tingkat Social Anxiety Disorder Remaja Hengky Anra, Helen Sastypratiwi, Muslimah Muslimah	PDF 67 - 75
Data Mining untuk Pengelompokan Saham pada Sektor Energi dengan Metode K-Means Anggi Srimurdianti Sukanto, Wawan Setiawan, Enda Esyudha Pratama	PDF 76 - 81
Penentuan Jalur Evakuasi dan Titik Kumpul Partisipatif untuk Keselamatan Masyarakat di Radius Zona Perencanaan Kedaruratan Nuklir Kalimantan Barat Berbasis Spasial Muhammad Azhar Irawansyah, Yarlina Yacoub, Metasari Kartika, Bintoro Bagus Purmono, Romi Suradi, Sunarko Sunarko, Siti Alimah, Euis Ety Alhakim	PDF 82 - 88
Evaluasi Kinerja Internet Kamus Universitas Tanjungpura dengan Analisis Quality of Service dan User Acceptance Test Herry Sujaini, Muanuddin -, Fitri Imansyah, Yus Sholva, Ferry Hadary, Eva Dolorosa, Andi Iwuan, Mochammad Meddy Danial, Silvia Uslianti, Purwaningsih -, Dwi Zulfitra, Aktris Nuryanti, Rommy Patra, Yuline -, Stepanus Sahala Sitompul, Syafulrahman -, Alhadlansyah -, Muhammad Yusuf, Achmadi -, Rachmawati -, Wendy -, Hamdani -, Syarif Hasyim Azizurrahman, Wirtasa -, Endang Purwaningsih, Syamswisna -, Bistari -, Ade Mirza, Asep Nursangaji, Ratna Herawatiningsih, Kurnia Ningsih, Surachman -, Meiran Panggabean, Siti Hadijah, Rahmidiyani -, Priyo Saptomo, Memet Agustiar, Vivi Bachtiar, Afrizal -, Setia Budi, Yohanes Gatot Sutapa, Windhu Putra, Nurmainah -, Ely Suharlina, Zubaidah R, Erni Djun Astuti, Muhsin -, Riduansyah -, Agustina Listiawati, Imam Ghozali, Ade Elbani, Yulis Jamiah, Edy Suasono, Ismawartati -, Aswandi -, Uti Asikin, Siti Halidjah	PDF 89 - 95
Pemanfaatan Metode TOPSIS dalam Merancang Aplikasi Pendukung Keputusan untuk Memberikan Rekomendasi Hasil Medical Check Up pada Rumah Sakit Ricky Akbar, Adi Arga Arifnur, Jefril Rahmadoni, Salsabila Julia Putri	PDF 96 - 104
Penerapan Convolutional Neural Network (CNN) dan Euclidean Distance Matrices (EDM) untuk Mengurangi False Positive pada Pengenalan Aktifitas Finger Point Call Rila Mandala, Mohammad Deny Safari	PDF 105 - 114
Social Network Analysis untuk Identifikasi Pengguna Twitter Berpengaruh pada Topik Bencana Gempa dan Tsunami di Indonesia Ibnu Santoso, Siskarossa Ika Oktora, Siti Muchlisoh, Ernawati Pasaribu	PDF 115 - 122
Pemilihan Kata Benda Bahasa Indonesia Berdasarkan Cakupan Suku Kata Menggunakan Genetic Algorithm untuk Dataset Audio Visual Eka Rahayu Setyaningsih, Anik Nur Handayani, Wahyu Sakti Gunawan Irianto, yosi Kristian	PDF 123 - 128
Prediksi Harga Saham Jakarta Islamic Index Menggunakan Metode Long Short-Term Memory Didih Rizki Chandranegara, Raffi Ainul Afif, Christian Sri Kusuma Aditya, Wildan Suharso, Hardianto Wibowo	PDF 129 - 135
Rekayasa Sistem Fotosintesis dan Ekosistem pada Media Aquascape Berbasis Internet Of Things Ikhwan Ruslianto, Uray Ristian, Hirzen Hasfani, Kartika Sari	PDF 136 - 142
Analisis Perbandingan Multiple Regression dan Priority Quadrant terhadap Kepuasan Mahasiswa dalam E-learning Menggunakan Metode Servqual Yunlia Mulyani Azis, Rr Rachmawati, Moehammad Sarosa	PDF 143 - 147
Rapid Application Development untuk Pengembangan Sistem Informasi Pengelolaan Barang Milik Negara (Studi Kasus UPT PPD Wilayah Sintang) Emilia Ramadhanty Gunawan, Eva Faja Ripanti, Haried Novriando	PDF 148 - 158
Model Meta Ensemble dan Deep Learning untuk Prediksi Emiten LQ45 Hendra Bunyamin, Oktavianti Oktavianti, Meyliana Meyliana	PDF 159 - 167



This work is licensed under a [Creative Commons Attribution-NonCommercial-ShareAlike 4.0 International License](https://creativecommons.org/licenses/by-nc-sa/4.0/).
01326592 [View MyStat](#)

OPEN JOURNAL SYSTEMS



Journal Help

USER

Username

Password

Remember me

JOURNAL CONTENT

Search

Search Scope

All

Browse

- [By Issue](#)
- [By Author](#)
- [By Title](#)
- [Other Journals](#)

CURRENT ISSUE



KEYWORDS

[Akurasi Analisis Sentimen Android CNN](#)
[Clustering Data Mining Decision Tree](#)
[Deep Learning K-Means KNN](#)
[Klasifikasi LSTM Machine](#)
[Learning Naive Bayes Naive Bayes](#)
[Prediksi Random Forest SVM Sistem](#)
[Informasi Support Vector Machine TF-IDF](#)

FONT SIZE



Model Meta *Ensemble* dan *Deep Learning* untuk Prediksi Emiten LQ45

Hendra Bunyamin^{#1}, Oktavianti^{*2}, Meyliana^{*3}

[#]Fakultas Teknologi Informasi Universitas Kristen Maranatha
Jalan Prof. drg. Suria Sumantri No.65 Bandung

¹hendra.bunyamin@it.maranatha.edu

^{*}Fakultas Bisnis Universitas Kristen Maranatha
Jalan Prof. drg. Suria Sumantri No.65 Bandung

²oktavianti@eco.maranatha.edu

³meyliana@eco.maranatha.edu

Abstrak— LQ (Liquid) 45 merupakan indeks saham yang berisi 45 emiten yang dipilih berdasarkan pertimbangan likuiditas dan kapitalisasi pasar, dengan kriteria-kriteria sebagai berikut: telah tercatat di BEI minimal 3 bulan, aktivitas transaksi di pasar reguler yaitu nilai, *volume*, dan frekuensi transaksi, jumlah hari perdagangan di pasar reguler, kapitalisasi pasar pada periode waktu tertentu, dan keadaan keuangan dan prospek pertumbuhan perusahaan tersebut. Dengan mengetahui emiten-emiten yang akan masuk ke dalam indeks LQ 45, para investor akan sangat terbantu dalam merencanakan portofolio mereka di masa yang akan datang. Penelitian ini bertujuan membangun model prediksi bagi emiten-emiten yang akan masuk ke dalam LQ 45. Dataset terdiri dari ringkasan saham semua emiten dari 1 Februari 2015 sampai dengan Januari 2022 dan daftar emiten-emiten yang masuk ke dalam LQ 45 dari periode Agustus 2015-Januari 2016 sampai dengan Februari 2022-Juli 2022. Indeks LQ 45 sendiri diperbaharui setiap 6 bulan sekali; oleh karena itu, dalam penelitian ini model prediksi per 6 bulan dibentuk dan dilatih dengan 4-fold cross-validation. Model-model prediksi, yaitu HIVE-COTE 2.0, ROCKET, *multi-layer perceptron*, *stacking recurrent neural networks*, dan *bi-directional recurrent neural networks* memberikan hasil bahwa HIVE-COTE 2.0 HIVE-COTE 2.0 memberikan kinerja terbaik dalam *precision*, yaitu keunggulan sekitar 9% daripada model-model lainnya dalam memprediksi emiten-emiten jika kriteria yang dipertimbangkan adalah mengurangi *false positive*. Jika kriteria yang diutamakan adalah menjaga keseimbangan antara mengurangi *false positive* dan *false negative*, maka model *multi-layer perceptron* dengan banyak neuron yang cukup besar (512) juga memberikan F1 score yang lebih tinggi 9% daripada model-model lain dalam memprediksi emiten-emiten yang akan masuk LQ 45.

Kata kunci— LQ45, *Machine Learning*, *Deep Learning*, HIVE-COTE 2.0, ROCKET, *Recurrent Neural Networks*.

I. PENDAHULUAN

Definisi Emiten menurut Otoritas Jasa Keuangan (OJK) adalah pihak yang melakukan penawaran umum, yaitu

penawaran surat berharga yang dapat diperdagangkan (efek), seperti surat saham dan surat obligasi kepada masyarakat berdasarkan tata cara yang diatur dalam peraturan Undang-undang yang berlaku [1]. Khususnya, emiten saham adalah perorangan atau perusahaan yang menjual saham dan saham tersebut ditawarkan di pasar modal, seperti Indonesia *Stock Exchange* (IDX). Adapun indeks saham di IDX adalah ukuran statistik yang mencerminkan keseluruhan pergerakan harga atas sekumpulan saham yang dipilih berdasarkan kriteria dan metodologi tertentu serta dievaluasi secara berkala [2]. Terdapat 5 (lima) manfaat dari indeks saham, yaitu bahwa indeks saham dapat:

1. Mengukur sentimen pasar. Indeks merupakan alat untuk mengukur sentimen pasar atau kepercayaan investor. Perubahan nilai di indeks mencerminkan opini kolektif dari seluruh pelaku pasar.
2. Menjadi acuan atau referensi untuk produk investasi pasif seperti Reksa Dana Indeks dan ETF Indeks serta produk turunan. Indeks saham juga dapat digunakan sebagai acuan atau basis bagi produk investasi ("*index tracking products*") lainnya, seperti reksa dana indeks yang mengikuti acuan indeks saham tertentu. Misalnya, reksa dana indeks saham X akan menggunakan acuan indeks saham X untuk memastikan bahwa portofolio (kumpulan investasi keuangan) yang dikelola oleh manager investasi sesuai dengan indeks tersebut.
3. Menjadi *benchmark* bagi portofolio aktif. Indeks saham dapat digunakan sebagai *benchmark* bagi portofolio aktif. Artinya adalah *benchmark* ditentukan sesuai dengan portofolio sehingga kinerja produk investasi dalam portofolio dapat diukur. Sebagai contoh, ketika investor menginvestasikan saham-saham di sektor keuangan, maka indeks yang lebih tepat menjadi *benchmark* adalah indeks sektor keuangan daripada Indeks Harga Saham Gabungan (IHSG).

4. Menjadi proksi dalam mengukur dan membuat model pengembalian investasi (return), risiko sistematis, dan kinerja yang disesuaikan dengan risiko [3]. Contohnya, *Capital Asset Pricing Model* (CAPM) mendefinisikan beta (β) sebagai risiko sistematis terhadap risiko pasar. Portofolio pasar dalam CAPM memuat seluruh efek berisiko. Umumnya, indeks komposit, seperti IHSG digunakan sebagai proksi untuk portofolio pasar, yang kemudian dapat digunakan untuk menghitung risiko sistematis dan kinerja yang disesuaikan dengan risiko suatu portofolio.
5. Menjadi proksi untuk kelas aset pada alokasi aset. Karena indeks saham memuat profil risiko dan pengembalian investasi dari sekelompok saham, indeks saham dapat dijadikan proksi pada alokasi aset.

Menurut Indonesia *Stock Exchange* [4] LQ (Liquid) 45 merupakan indeks saham yang berisi 45 emiten yang dipilih berdasarkan pertimbangan likuiditas dan kapitalisasi pasar, dengan kriteria-kriteria yang telah ditentukan. Adapun kriteria-kriteria yang digunakan untuk menentukan apakah suatu emiten dapat masuk dalam perhitungan indeks LQ 45 adalah:

- Telah tercatat di BEI minimal 3 bulan.
- Aktivitas transaksi di pasar reguler yaitu nilai, *volume*, dan frekuensi transaksi.
- Jumlah hari perdagangan di pasar reguler.
- Kapitalisasi pasar pada periode waktu tertentu.
- Selain mempertimbangkan kriteria likuiditas dan kapitalisasi pasar tersebut di atas, akan dilihat juga keadaan keuangan dan prospek pertumbuhan perusahaan tersebut.

LQ 45 merupakan indeks saham tertua kedua (diluncurkan pada tanggal 1 Februari 1997) setelah IHSG dengan jumlah konstituen yang jauh lebih sedikit (45 emiten) daripada IHSG (713 emiten) [5]. Selain itu, saham-saham LQ 45 dapat dikatakan merupakan saham-saham dari perusahaan-perusahaan yang memiliki fundamental yang baik. Dengan mengetahui emiten-emiten yang akan masuk ke dalam indeks LQ 45, para investor akan sangat terbantu dalam merencanakan portofolio mereka di masa yang akan datang.

Penelitian ini bertujuan membangun model prediksi bagi emiten-emiten yang akan masuk ke dalam LQ 45. Dengan adanya model prediksi ini, para investor akan terbantu dalam perancangan portofolio mereka. Salah satu contoh nyatanya adalah para investor dapat menginvestasikan saham-saham sebelum saham-saham tersebut masuk ke dalam LQ 45.

Penelitian sebelumnya yang dilakukan terkait dengan saham LQ45 serta *time series forecasting* disajikan terlebih dahulu pada bagian ini:

A. Penelitian Terkait LQ45

Penelitian [6] menggunakan data dari perusahaan LQ 45 yang terdaftar di BEI selama periode 2008-2012 dengan tujuan untuk memprediksi arus kas masa depannya. Adapun variabel-variabel independen (*feature*) yang

digunakan adalah kemampuan laba bersih, arus kas, perubahan piutang, dan perubahan hutang. Lebih lanjut, model yang digunakan untuk memprediksi adalah model regresi linier dengan hasil bahwa laba bersih dan arus kas berpengaruh signifikan terhadap arus kas di masa depan. Penelitian prediksi arus kas masa depan yang mirip juga dilakukan oleh [7] dan [8].

Penelitian yang dilakukan [9] meneliti masalah prediksi indeks saham harian LQ 45 dari *Bank Central Asia Tbk.* yang diambil dari 1 Juli 2009 s.d. 1 Agustus 2013. *Feature-feature* yang digunakan untuk model-model dibagi menjadi tiga model, yaitu 1 lag, 6 lag, dan 10 lag dan masing-masing memiliki dua arsitektur model, yaitu *Multilayer Perceptron* (MLP) dan *Support Vector Regression* (SVR). Hasil eksperimen menunjukkan bahwa model SVR dengan 10 lag memberikan prediksi lebih baik daripada MLP. Penelitian lainnya adalah mengenai prediksi tiga harga saham yang termasuk dalam LQ 45, yaitu ASII (PT Astra International, Tbk.), KLB (PT Kalbe Farma, Tbk.), dan TLKM (PT Telkom Indonesia, Tbk.) yang dilakukan dengan jumlah data sebanyak 511 hari dari tanggal 31 Mei 2018 s.d. 29 Mei 2020 dan model prediksi yang dibentuk adalah MLP [10], [11]. Selain SVR, penelitian lain mencoba menggunakan *Support Vector Machine* (SVM) [12].

Penelitian terdahulu [13] meneliti masalah prediksi indeks LQ 45 untuk bulan Januari 2021, Februari 2021, dan Maret 2021. Data latih (training data) adalah indeks LQ 45 dari Januari 2014 s.d. Desember 2020 yang dimasukkan ke dalam dua model, yaitu *Holt-Winter's Exponential Smoothing* dan *Weighted Fuzzy Integrated Time Series*. Hasil empiris menunjukkan bahwa Mean *Absolute Percentage Error* (MAPE) dari *Weighted Fuzzy Integrated Time Series* lebih rendah daripada MAPE dari *Holt-Winter's Exponential Smoothing*. Sedangkan [14] meneliti masalah prediksi indeks LQ 45 dengan algoritma *Autoregressive Integrated Average* (ARIMA) dan *training data* yang digunakan adalah harga saham dari *BBCA (Bank Central Asia Tbk.)* dari 29 November 2019 s.d. 29 Mei 2020. Penelitian yang mirip juga dilakukan oleh [15] [16] [17].

Selain itu, terdapat juga penelitian-penelitian terkait dengan analisis pembentukan portofolio optimal dari saham-saham LQ 45 dengan metode indeks tunggal [18], memprediksi pergerakan harga saham melalui analisis profitabilitas [19] dan menganalisis pengaruh kinerja keuangan terhadap harga saham [20].

Dari studi literatur yang telah dilakukan, penelitian-penelitian sebelumnya membahas prediksi arus kas masa depan perusahaan LQ 45, prediksi indeks saham harian LQ 45, prediksi harga saham yang termasuk dalam LQ 45, analisis pembentukan portofolio optimal dari saham-saham LQ 45, prediksi pergerakan harga saham, dan analisis pengaruh kinerja keuangan terhadap harga saham. Oleh karena itu, kebaruan dari penelitian ini adalah pembangunan model untuk memprediksi perusahaan-perusahaan yang akan masuk ke LQ 45 dan masalah ini

belum pernah dibahas oleh penelitian-penelitian sebelumnya.

B. Time Series Forecasting dengan RNN

Time series merupakan barisan terurut dari observasi [21]. Umumnya, barisan ini terurut berdasarkan interval waktu yang sama. Contohnya, *time series* dari harga saham per hari. Dalam contoh ini, barisan harga saham ini terurut menurut interval waktu harian. Contoh kedua adalah hasil penjualan setiap tiga bulan. Pada contoh kedua ini, barisan hasil penjualan terurut menurut interval waktu tiga bulanan.

Teknik *forecasting* tergantung pada data yang tersedia. Apabila tidak ada *history* data atau data yang tersedia tidak relevan untuk prediksi, teknik *qualitative forecasting* yang harus digunakan. Selain *qualitative forecasting*, terdapat *quantitative forecasting* yang dapat digunakan jika dua kondisi terpenuhi, yaitu:

- *history* data adalah data numerik,
- asumsi bahwa beberapa aspek dari pola terdahulu akan berlanjut di masa depan.

Umumnya, masalah *quantitative prediction* menggunakan data *time series* yang dikumpulkan pada interval waktu yang tetap atau menggunakan data *cross-sectional* yang dikumpulkan pada satu titik waktu tertentu. Penelitian ini akan berfokus pada *quantitative forecasting* dengan data *time series* karena data *time series* yang diprediksi adalah masuk ke LQ 45 atau tidak.


Recurrent Neural Network (RNN) adalah *neural network* yang memetakan ruang *input* yang terdiri atas barisan-barisan ke ruang *output* yang juga terdiri dari barisan-barisan sedemikian sehingga prediksi untuk *output* y_t bergantung tidak hanya pada input x_t , tetapi juga pada *hidden state* dari sistem, h_t yang terus menerus di-*update* selama barisan diproses. RNN dapat digunakan untuk *sequence generation*, *sequence classification*, dan *sequence translation* [22]. Masalah dalam penelitian ini termasuk dalam kategori *sequence classification*; oleh karenanya, RNN akan digunakan sebagai salah satu model prediksi.

Asumsikan bahwa sebuah vektor *output* y dengan panjang *output* tetap yang hendak diprediksi dan *input* yang berupa barisan sebagai input. Fungsi yang berbentuk $f\theta: \mathbb{R}^T \times \mathbb{D} \rightarrow \mathbb{R}^C$. Fungsi ini disebut model *seq2vec*. Dalam penelitian ini, label *class* sebagai *output* adalah $y \in \{0, 1\}$ dengan 1 masuk LQ 45 dan 0 sebaliknya.

Pendekatan paling sederhana untuk memprediksi adalah menggunakan state akhir dari RNN sebagai *input* dari *classifier* [22].


$$P(y | x_{1:T}) = \text{Cat}(y | S(W h_T)) \tag{1}$$

dengan y adalah nilai yang akan diprediksi, S adalah fungsi softmax, W adalah matriks bobot, h_T adalah state akhir dari RNN, dan $\text{Cat}(y | \theta)$ didefinisikan sebagai $\prod_{c=1}^C \theta_c^{I(y=c)}$, sesuai dengan notasi yang digunakan di *Murphy* [22].



Gambar. 1 RNN untuk *sequence classification* [22]

Model RNN menggunakan konteks *state backward* ($h_T, h_{T-1}, h_{T-2}, \dots$). Umumnya, hasil prediksi lebih baik jika RNN menggunakan kombinasi konteks *state backward* ($h_T, h_{T-1}, h_{T-2}, \dots$) dan *state forward* (h_1, h_2, h_3, \dots). Model RNN ini disebut *bidirectional RNN* [23] dan terdiri dari dua RNN, yaitu RNN pertama menghitung *hidden state* ke arah *forward* secara rekursif dan RNN kedua menghitung *hidden state* ke arah *backward* secara rekursif.



Gambar. 2 Bidirectional RNN untuk *sequence classification* [22]

Secara spesifik, model ini diilustrasikan di Gambar 2 dan didefinisikan sebagai berikut:

$$\vec{h}_t = \varphi(\vec{W}_{xh} x_t + \vec{W}_{hh} \vec{h}_{t-1} + \vec{b}_h) \tag{2}$$

Selanjutnya, h_t didefinisikan sebagai $h_t = [h_{t \rightarrow}, h_{t \leftarrow}]$ sebagai representasi *state* pada saat t , menggabungkan informasi masa lalu dan masa depan. Terakhir, *hidden state- hidden state* ini dikenakan operasi *average pool* untuk memperoleh *final classifier*:


$$P(y | x_{1:T} = \text{Cat}(y | WS(\bar{h}))) \tag{3}$$

$$\bar{h} = \frac{1}{T} \sum_{t=1}^T h_t \tag{4}$$

Model *bidirectional RNN* sering juga disebut *Swiss Army knife model deep learning* untuk *natural language processing* [24].

C. Multi-layer Perceptron (MLP)

Model *Multi-layer Perceptron* (MLP) adalah model yang terinspirasi dari *neuron-neuron* di otak manusia. Setiap *neuron* dalam MLP direpresentasikan sebagai mesin komputasi seperti pada Gambar 3.



Gambar. 3 Contoh MLP dengan satu *hidden layer* dan satu *neuron* di *output layer*

MLP terdiri dari tiga *layer* utama, yaitu *input layer*, *hidden layer*, dan *output layer*. Setiap *neuron* di *hidden layer* dihubungkan dengan setiap *neuron* di *input* dan *output layer*. Garis-garis penghubung disebut bobot dan nilai *neuron* di *hidden layer* dihitung melalui dua tahap. Tahap pertama adalah menjumlahkan perkalian *neuron* dengan bobot dan tahap kedua adalah menerapkan fungsi aktivasi pada hasil jumlah tersebut. selanjutnya. Gambar 3 menggambarkan MLP dengan satu *hidden layer*. MLP dapat memiliki lebih dari satu *hidden layer* dan *output layer* juga dapat mempunyai lebih dari satu *neuron*. Jumlah *neuron* di *output layer* disesuaikan dengan *task* yang dihadapi oleh MLP; contohnya, *task* untuk klasifikasi biner menggunakan satu *neuron*.

Proses learning dalam MLP terjadi ketika terdapat perbedaan antara hasil prediksi dan nilai sebenarnya (*error*) di *output layer*. Bobot akan di-*update* berdasarkan *error* dengan menggunakan algoritma berbasis *gradient descent*. Dengan bobot yang terus menerus ter-*update*, jumlah prediksi MLP yang benar akan semakin banyak dan kinerja akan semakin baik.

D. Hierarchical Vote Collective of Transformation-based Ensembles 2.0 (HIVE-COTE 2.0)

Model terakhir yang merupakan algoritma *state-of-the-art* untuk keakuratannya di masalah *time series classification* adalah *Hierarchical Vote Collective of Transformation-based Ensembles 2.0* (HIVE-COTE 2.0) [25]. HIVE-COTE 2.0 merupakan *ensemble* empat *classifier* dari berbagai domain yang mencakup *Shapelet Transform Classifier* (STC) [26] yang berbasis *Shapelet*, *ensemble ROCKET classifier* berbasis *convolution* yang bernama Arsenal, representasi *Temporal Dictionary Ensemble* (TDE) yang berbasis *dictionary*, DrCIF yang berbasis interval.

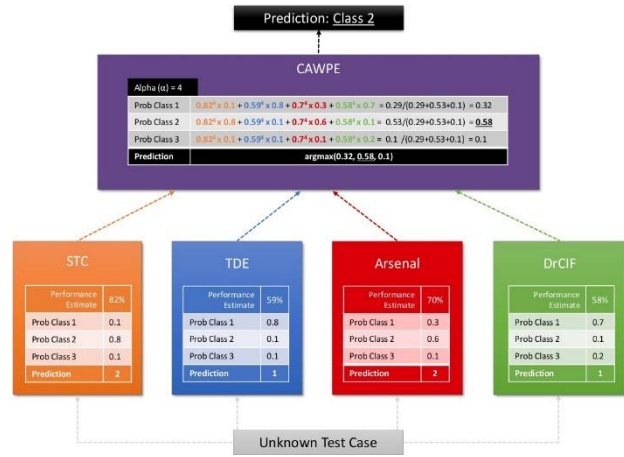
Gambar 4 menjelaskan bahwa ensemble HIVE-COTE 2.0 mempunyai satu *hyperparameter* (α), contoh: $\alpha = 4$. Masing-masing *classifier* dilatih dan nilai perkiraan kinerja (*performance estimate*) masing-masing *classifier* diperoleh.

Misalkan kinerja1 = kinerja *classifier* STC, kinerja2 = kinerja TDE, kinerja3 = kinerja Arsenal, dan kinerja4 = kinerja DrCIF. Definisikan juga (Prob Class 1)_j adalah peluang Class 1 dari *classifier* j, maka

$$\text{Prob Class 1} = \frac{\sum_{k=1}^4 (\text{kinerja}_k)^\alpha \times (\text{Prob Class 1})_k}{\sum_{i=1}^3 \text{Prob Class } i}$$

$$\text{Prob Class 2} = \frac{\sum_{k=1}^4 (\text{kinerja}_k)^\alpha \times (\text{Prob Class 2})_k}{\sum_{i=1}^3 \text{Prob Class } i}$$

$$\text{Prob Class 3} = \frac{\sum_{k=1}^4 (\text{kinerja}_k)^\alpha \times (\text{Prob Class 3})_k}{\sum_{i=1}^3 \text{Prob Class } i}$$



Gambar. 4 Struktur ensemble HIVE-COTE 2.0

Gambar. 4 Struktur ensemble HIVE-COTE 2.0 untuk masalah klasifikasi dengan tiga kelas [25]. Setiap *classifier* dilatih secara independen dan hasil prediksi dipilih berdasarkan nilai peluang terbesar

Selanjutnya, nilai prediksi dari HIVE-COTE 2.0 adalah Prediksi Kelas = $\text{argmax}\{\text{Prob Class 1, Prob Class 2, Prob Class 3}\}$.

II. METODE

Secara umum, penelitian ini akan membandingkan kinerja model *Multilayer Perceptron* (MLP), *Recurrent Neural Network* (RNN), *Bidirectional RNN* (Bi-RNN), ROCKET, dan HIVE-COTE 2.0 (HC-2) dalam memprediksi perusahaan-perusahaan yang akan masuk ke dalam LQ 45 dari Februari 2015 s.d. Januari 2022. Gambar 5 adalah tahapan-tahapan dalam metode penelitian yang dilakukan. Tahap pertama adalah menentukan model yang cocok dengan permasalahan yang dihadapi. Tahap kedua adalah *dataset* yang berupa *time series* dimodelkan dan tahap ketiga adalah metrik evaluasi kinerja yang diukur untuk melihat keakuratan model.



Gambar. 5 Tahapan-tahapan dalam penelitian ini

A. Penentuan Model yang Cocok Dengan Masalah

Informasi semua saham dari Februari 2015 s.d. Januari 2022 diunduh dari *website* idx.co.id. Selanjutnya, empat fitur yang menjadi kriteria untuk masuk LQ 45 (nilai, volume, frekuensi, dan harga penutupan) diekstraksi. Pergerakan empat fitur tersebut dari Februari 2015 s.d. Januari 2022 adalah empat *time series* sehingga masalah ini

dikategorikan sebagai *multivariate time series* [27]. Lebih lanjut, masalah ini merupakan *time series classification* karena setiap *time series* akan ditentukan apakah *time series* tersebut masuk ke dalam LQ 45 atau tidak.

Daftar saham yang masuk LQ 45 diumumkan setiap 6 bulan; oleh karena itu, dataset dibagi menjadi beberapa sub-dataset yang masing-masing terdiri dari 6 bulan. Lebih spesifik, banyak sub-dataset yang terbentuk adalah sebanyak 14. Emiten- emiten yang dimasukkan ke dalam dataset adalah emiten-emiten dengan nilai fitur yang tidak nol untuk setiap fitur.

Model-model Multilayer Perceptron (MLP), Recurrent Neural Network (RNN), Bidirectional RNN (Bi-RNN), ROCKET, dan HIVE-COTE 2.0 (HC-2) dilatih pada setiap sub-dataset dengan menggunakan K-Fold cross-validation (CV) karena CV cocok untuk dataset yang berukuran kecil [28] [29].

B. Pemodelan Time Series

Multivariate time series yang terdiri dari empat fitur ini dimodelkan dengan MLP yang merupakan model yang pertama. Empat fitur tersebut dinormalisasi terlebih dahulu dengan z-normalization kemudian dimasukkan ke input layer yang memiliki jumlah neuron sebanyak 4; *input layer* pada Gambar 3 memiliki 3 neuron. Jumlah neuron yang digunakan adalah 512 pada satu *hidden layer* dengan fungsi aktivasi Rectified Linear Unit (ReLU). *Output layer* yang terdiri dari satu neuron menggunakan fungsi sigmoid yang digunakan untuk masalah klasifikasi biner secara umum dan fungsi *loss* adalah *binary cross-entropy*. Jumlah *epoch* yang digunakan adalah 10 karena hasil eksperimen menunjukkan bahwa jumlah *epoch* yang melebihi tidak memberikan dampak yang signifikan. Adapun algoritma optimasi yang digunakan adalah Adam.

Selanjutnya, model kedua adalah model RNN. Secara khusus, model RNN dibentuk dengan menumpuk *layer recurrent*. Contoh *layer-layer recurrent* yang ditumpuk adalah pada Gambar 1 yang dilambangkan oleh h_1 , h_2 , dan h_3 . Jumlah *layer-layer* yang lebih dari 1 dilakukan untuk meningkatkan kapasitas *network* seperti yang diimplementasi pada *Google Translate*. Model RNN yang dibuat menggunakan dua *layer Gated Recurrent Unit (GRU)* dengan masing-masing 32 neuron dan spesifikasi probabilitas dropout adalah 0,5. Neuron di *output layer* yang berjumlah satu juga dikenakan *dropout*. Algoritma optimasi yang digunakan adalah Adam.

Model ketiga adalah Bi-RNN yang dideskripsikan di Gambar 2. Model ini adalah dua RNN yang dijalankan secara bertahap. RNN pertama dan kedua adalah RNN dengan *input time series* masing-masing sesuai dengan kronologi waktu dan kronologis waktu terbalik. Kedua RNN menggunakan satu *hidden layer Long Short-term Memory (LSTM)* yang memiliki 16 neuron. Jumlah neuron ini disesuaikan dengan kapasitas komputasi mesin yang ada. Semua pengaturan seperti fungsi aktivasi, fungsi *loss*, dan jumlah *epoch* sama seperti dua model sebelumnya. Tiga

model berbasis *deep learning* ini diimplementasi dengan menggunakan *framework Keras1* [24].

Selain model berbasis *deep learning*, dua model lainnya adalah Random Convolutional Kernel Transform (ROCKET) [30] dan HIVE-COTE 2.0 [25]. Model ROCKET menggunakan pengaturan default dan model HIVE-COTE 2.0 diatur dengan batas waktu pemrosesan 1 menit; hal ini dilakukan untuk menghindari lamanya proses memprediksi. Kedua model ini diimplementasi dengan memanfaatkan *library sktime2*

C. Pengukuran Metrik Evaluasi Kinerja

Memprediksi apakah sebuah emiten masuk ke dalam daftar LQ 45 merupakan hal yang lebih diutamakan daripada apakah sebuah emiten tidak masuk ke dalam LQ45. Oleh karena, metrik evaluasi yang digunakan adalah *precision* dan *F1 score*. *Precision* menunjukkan apakah perusahaan yang diprediksi masuk LQ 45 memang masuk ke LQ 45 dan ini merupakan metrik yang diinginkan oleh investor sedangkan *F1 score* digunakan untuk melihat keseimbangan antara *precision* dan *recall* dari prediksi yang dibuat.

III. HASIL DAN PEMBAHASAN

Pembentukan *train* dan *test* set diambil dari dataset yang terdiri dari empat X *time series* (nilai, *volume*, frekuensi, dan harga penutupan) dan y yang adalah *binary value* (1 = masuk LQ 45 dan 0 = tidak masuk LQ 45). Dataset dibentuk dari Februari 2015 s.d. Juli 2021 yang dibagi menjadi 14 periode sesuai dengan periode dirilisnya daftar LQ 45, yaitu 6 bulan.

TABEL I
DATASET 14 PERIODE

Periode	Durasi	#Emiten	#Hari
1	Feb 2015 s.d. Jul 2015	192	121
2	Ags 2015 s.d. Jan 2016	176	122
3	Feb 2016 s.d. Jul 2016	181	120
4	Ags 2016 s.d. Jan 2017	199	127
5	Feb 2017 s.d. Jul 2017	234	114
6	Ags 2017 s.d. Jan 2018	250	125
7	Feb 2018 s.d. Jul 2018	284	116
8	Ags 2018 s.d. Jan 2019	292	124
9	Feb 2019 s.d. Jul 2019	314	117
10	Ags 2019 s.d. Jan 2020	282	128
11	Feb 2020 s.d. Jul 2020	270	121
12	Ags 2020 s.d. Jan 2021	341	119
13	Feb 2021 s.d. Jul 2021	425	121
14	Ags 2021 s.d. Jan 2022	512	127

Tabel 1 menjelaskan dataset untuk setiap periode. Untuk menentukan suatu emiten yang masuk ke LQ 45 atau $y = 1$,

daftar emiten-emiten yang masuk LQ 45 digunakan. Sebagai contoh, untuk menentukan apakah emiten BBKA di periode 1 masuk LQ 45, maka digunakanlah daftar emiten yang masuk LQ45 dari periode 2. Selanjutnya model meta ensemble dan *deep learning* di setiap periode akan evaluasi dengan menggunakan *4-fold cross-validation*.

Evaluasi prediksi dengan *4-fold cross-validation* tiap-tiap periode pada model-model tersebut akan ditampilkan pada tabel 2 sampai dengan tabel 15.

TABEL II
HASIL 4-FOLD CV DI PERIODE 1: FEB 2015 S.D. JUL 2015

Nama Model	Precision ± Std (%)	F ₁ score ± Std (%)
ROCKET (<i>default setting</i>)	81.38 ± 10.09	75.82 ± 07.49
HC-2 (<i>time_limit_in_minutes=1</i>)	100.00 ± 00.00	79.08 ± 15.70
MLP (<i>one hidden=512</i>)	86.19 ± 11.21	92.18 ± 06.67
RNN (<i>double layer</i>)	96.88 ± 05.41	81.92 ± 08.61
Bi-RNN (<i>one LSTM=16</i>)	93.75 ± 10.82	88.05 ± 04.43

Pada Tabel II, F₁ model MLP lebih baik sebesar 3% daripada Bi-RNN. Hal ini menunjukkan bahwa satu *hidden layer* dengan jumlah neuron yang banyak (512) mampu memprediksi lebih baik daripada penggunaan dua layer LSTM pada model Bi-RNN tetapi perlu diingat bahwa masih terdapat sekitar 8% ruang kesalahan yang mungkin tidak diinginkan oleh investor apabila mereka akan menggunakan model ini. Selanjutnya, dalam hal *precision*, HC-2 tidak memiliki ruang kesalahan dalam memprediksi perusahaan-perusahaan yang akan masuk LQ 45 dan model ini akan lebih diminati oleh investor untuk digunakan.

TABEL III
HASIL 4-FOLD CV DI PERIODE 2: AGT 2015 S.D. JAN 2016

Nama Model	Precision ± Std (%)	F ₁ score ± Std (%)
ROCKET (<i>default setting</i>)	71.14 ± 02.21	65.91 ± 05.94
HC-2 (<i>time_limit_in_minutes=1</i>)	90.97 ± 10.28	75.68 ± 05.27
MLP (<i>one hidden=512</i>)	90.60 ± 09.71	94.79 ± 05.41
RNN (<i>double layer</i>)	83.30 ± 13.65	77.54 ± 06.91
Bi-RNN (<i>one LSTM=16</i>)	78.78 ± 15.81	77.26 ± 12.21

Hasil yang mirip Tabel II juga terjadi pada Tabel III tetapi dalam periode ini F₁ MLP mengungguli RNN sebesar 17%.

TABEL IV
HASIL 4-FOLD CV DI PERIODE 3: FEB 2016 S.D. JUL 2016

Nama Model	Precision ± Std (%)	F ₁ score ± Std (%)
ROCKET (<i>default setting</i>)	68.75 ± 16.72	62.47 ± 15.29
HC-2 (<i>time_limit_in_minutes=1</i>)	87.01 ± 17.64	74.39 ± 17.11
MLP (<i>one hidden=512</i>)	87.82 ± 13.73	87.37 ± 06.06

Nama Model	Precision ± Std (%)	F ₁ score ± Std (%)
RNN (<i>double layer</i>)	79.79 ± 15.57	67.29 ± 13.05
Bi-RNN (<i>one LSTM=16</i>)	91.60 ± 08.45	87.30 ± 03.84

TABEL V
HASIL 4-FOLD CV DI PERIODE 4: AGT 2015 S.D. JAN 2017

Nama Model	Precision ± Std (%)	F ₁ score ± Std (%)
ROCKET (<i>default setting</i>)	79.76 ± 04.84	68.58 ± 07.01
HC-2 (<i>time_limit_in_minutes=1</i>)	96.43 ± 06.19	73.07 ± 07.84
MLP (<i>one hidden=512</i>)	88.78 ± 03.17	91.76 ± 02.04
RNN (<i>double layer</i>)	85.16 ± 14.85	70.38 ± 08.13
Bi-RNN (<i>one LSTM=16</i>)	97.50 ± 04.33	86.39 ± 04.99

Hasil yang menarik terjadi pada Tabel IV dan V ketika *precision* dari Bi-RNN dapat mengimbangi *precision* dari HC-2; maksimum perbedaan keduanya sekitar 5%. Ternyata, dua RNN yang masing-masing memiliki kronologis berlawanan mempunyai kapabilitas dalam memprediksi tetapi kekonsistenan Bi-RNN masih perlu diuji pada periode-periode berikutnya.

TABEL VI
HASIL 4-FOLD CV DI PERIODE 5: FEB 2017 S.D. JUL 2017

Nama Model	Precision ± Std (%)	F ₁ score ± Std (%)
ROCKET (<i>default setting</i>)	45.90 ± 16.22	37.86 ± 08.69
HC-2 (<i>time_limit_in_minutes=1</i>)	79.17 ± 21.65	40.50 ± 15.74
MLP (<i>one hidden=512</i>)	75.68 ± 08.03	72.01 ± 00.87
RNN (<i>double layer</i>)	82.34 ± 06.60	65.23 ± 07.47
Bi-RNN (<i>one LSTM=16</i>)	84.62 ± 09.70	74.71 ± 04.46

TABEL VII
HASIL 4-FOLD CV DI PERIODE 6: AGT 2017 S.D. JAN 2018

Nama Model	Precision ± Std (%)	F ₁ score ± Std (%)
ROCKET (<i>default setting</i>)	46.31 ± 13.99	33.34 ± 08.92
HC-2 (<i>time_limit_in_minutes=1</i>)	85.42 ± 14.88	41.20 ± 09.66
MLP (<i>one hidden=512</i>)	69.09 ± 02.92	73.19 ± 06.85
RNN (<i>double layer</i>)	78.19 ± 14.27	69.63 ± 08.09
Bi-RNN (<i>one LSTM=16</i>)	73.56 ± 17.85	66.44 ± 12.26

Tabel VI menunjukkan kecenderungan yang mirip dengan Tabel IV dan V, yaitu *precision* Bi-RNN mengungguli HC-2 sebesar 6% tetapi Tabel VII menunjukkan *precision* HC-2 mengungguli *precision* dari Bi-RNN sebesar 11%.

TABEL VIII
HASIL 4-FOLD CV DI PERIODE 7: FEB 2018 S.D. JUL 2018

Nama Model	Precision ± Std (%)	F ₁ score ± Std (%)
ROCKET (<i>default setting</i>)	92.86 ± 12.37	61.36 ± 08.43
HC-2 (<i>time_limit_in_minutes=1</i>)	100.00 ± 00.00	60.47 ± 11.47
MLP (<i>one hidden=512</i>)	78.57 ± 14.02	76.52 ± 11.67
RNN (<i>double layer</i>)	75.74 ± 14.51	65.54 ± 04.11
Bi-RNN (<i>one LSTM=16</i>)	75.99 ± 15.63	76.53 ± 05.69

TABEL IX
HASIL 4-FOLD CV DI PERIODE 8: AGT 2018 S.D. JAN 2019

Nama Model	Precision ± Std (%)	F ₁ score ± Std (%)
ROCKET (<i>default setting</i>)	75.00 ± 25.98	33.47 ± 04.21
HC-2 (<i>time_limit_in_minutes=1</i>)	100.00 ± 00.00	32.43 ± 18.02
MLP (<i>one hidden=512</i>)	80.63 ± 03.85	81.07 ± 02.20
RNN (<i>double layer</i>)	72.47 ± 10.59	74.39 ± 04.47
Bi-RNN (<i>one LSTM=16</i>)	76.90 ± 14.35	81.93 ± 07.87

Tabel VIII dan IX kembali menunjukkan kekonsistenan *precision* dari HC-2 sedangkan *F₁ score* Bi-RNN yang merupakan modifikasi dari MLP mengungguli *F₁ score* MLP itu sendiri dengan selisih kurang dari 1%.

TABEL X
HASIL 4-FOLD CV DI PERIODE 9: FEB 2019 S.D. JUL 2019

Nama Model	Precision ± Std (%)	F ₁ score ± Std (%)
ROCKET (<i>default setting</i>)	72.92 ± 18.04	34.23 ± 07.28
HC-2 (<i>time_limit_in_minutes=1</i>)	95.00 ± 08.66	50.23 ± 13.71
MLP (<i>one hidden=512</i>)	70.00 ± 08.50	76.70 ± 06.52
RNN (<i>double layer</i>)	77.71 ± 10.26	73.97 ± 13.90
Bi-RNN (<i>one LSTM=16</i>)	72.00 ± 05.77	75.71 ± 02.36

TABEL XI
HASIL 4-FOLD CV DI PERIODE 10: AGT 2019 S.D. JAN 2020

Nama Model	Precision ± Std (%)	F ₁ score ± Std (%)
ROCKET (<i>default setting</i>)	56.33 ± 08.49	44.08 ± 09.49
HC-2 (<i>time_limit_in_minutes=1</i>)	81.88 ± 14.29	58.87 ± 18.32
MLP (<i>one hidden=512</i>)	80.94 ± 11.93	84.56 ± 05.47
RNN (<i>double layer</i>)	84.41 ± 09.86	77.58 ± 05.99
Bi-RNN (<i>one LSTM=16</i>)	81.03 ± 14.44	75.20 ± 09.73

Kembali *precision* HC-2 mengungguli model lainnya, dalam hal ini RNN dengan margin 17% di Tabel X tetapi Tabel XI menunjukkan bahwa ada waktunya *precision*

RNN dapat mengungguli HC-2 tapi keunggulan ini kurang dari 2%.

TABEL XII
HASIL 4-FOLD CV DI PERIODE 11: FEB 2020 S.D. JUL 2020

Nama Model	Precision ± Std (%)	F ₁ score ± Std (%)
ROCKET (<i>default setting</i>)	86.67 ± 07.82	63.51 ± 05.81
HC-2 (<i>time_limit_in_minutes=1</i>)	100.00 ± 00.00	65.86 ± 09.16
MLP (<i>one hidden=512</i>)	85.68 ± 14.35	83.75 ± 07.49
RNN (<i>double layer</i>)	73.08 ± 10.74	68.50 ± 08.90
Bi-RNN (<i>one LSTM=16</i>)	70.57 ± 12.06	66.18 ± 11.93

TABEL XIII
HASIL 4-FOLD CV DI PERIODE 12: AGT 2020 S.D. JAN 2021

Nama Model	Precision ± Std (%)	F ₁ score ± Std (%)
ROCKET (<i>default setting</i>)	83.33 ± 16.67	40.06 ± 08.18
HC-2 (<i>time_limit_in_minutes=1</i>)	95.00 ± 08.66	50.42 ± 14.61
MLP (<i>one hidden=512</i>)	88.33 ± 09.57	84.53 ± 04.35
RNN (<i>double layer</i>)	72.56 ± 13.85	71.69 ± 07.76
Bi-RNN (<i>one LSTM=16</i>)	77.82 ± 16.67	72.61 ± 06.84

Tabel XII dan XIII kembali menunjukkan keunggulan *precision* dari HC-2 dari model-model lainnya masing-masing sebesar 13% dan 7%. Hal menarik terjadi pada Tabel XIII, yaitu ini adalah kali pertama *precision* MLP berada pada urutan ke-2.

TABEL XIV
HASIL 4-FOLD CV DI PERIODE 13: FEB 2021 S.D. JUL 2021

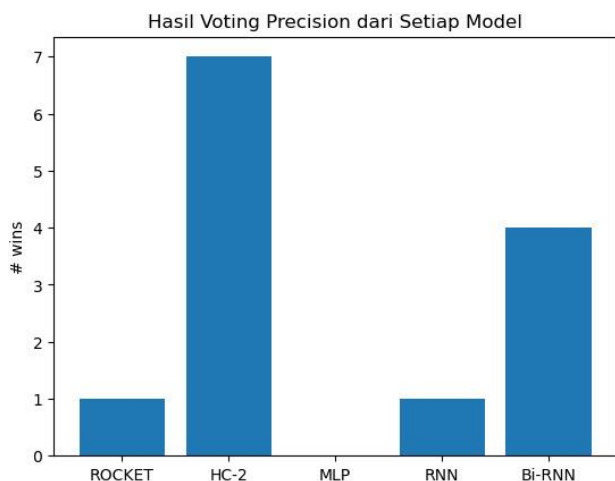
Nama Model	Precision ± Std (%)	F ₁ score ± Std (%)
ROCKET (<i>default setting</i>)	72.92 ± 30.83	26.35 ± 10.59
HC-2 (<i>time_limit_in_minutes=1</i>)	66.67 ± 40.82	20.08 ± 13.81
MLP (<i>one hidden=512</i>)	62.81 ± 22.25	65.53 ± 09.35
RNN (<i>double layer</i>)	39.81 ± 25.63	40.13 ± 24.13
Bi-RNN (<i>one LSTM=16</i>)	59.52 ± 09.67	59.29 ± 14.20

TABEL XV
HASIL 4-FOLD CV DI PERIODE 14: AGT 2021 S.D. JAN 2022

Nama Model	Precision ± Std (%)	F ₁ score ± Std (%)
ROCKET (<i>default setting</i>)	63.54 ± 26.58	29.42 ± 15.87
HC-2 (<i>time_limit_in_minutes=1</i>)	75.00 ± 43.30	17.04 ± 11.80
MLP (<i>one hidden=512</i>)	70.48 ± 08.58	74.39 ± 07.77
RNN (<i>double layer</i>)	73.27 ± 04.88	58.38 ± 05.08
Bi-RNN (<i>one LSTM=16</i>)	77.84 ± 16.26	57.06 ± 22.76

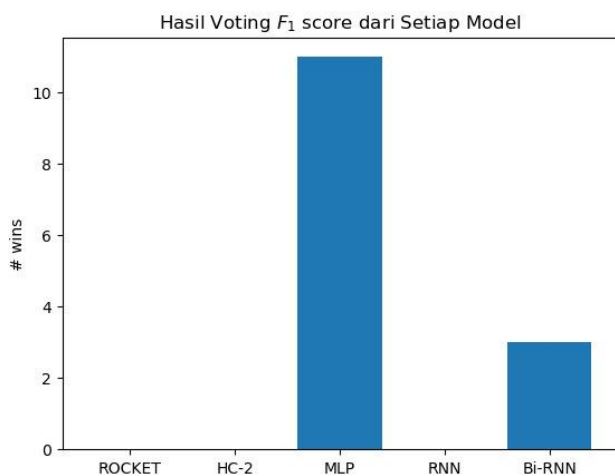
Tabel XIV menunjukkan pertama kalinya *precision* dari ROCKET mengungguli HC-2 dengan margin 6% dan *precision* dari Bi-RNN unggul sebesar 4% dari *precision* HC-2.

Hasil evaluasi prediksi dengan *4-fold cross-validation* pada model *meta ensemble* dan *deep learning* pada periode 1-14 seperti yang telah ditampilkan pada Tabel II sampai dengan Tabel XV memberikan hasil yang berbeda-beda tetapi secara keseluruhan dua model yang menonjol dalam hal konsistensi adalah HC-2 untuk metrik *precision* dan MLP untuk metrik F_1 score.



Gambar. 6 Hasil voting untuk precision dari setiap model pada keseluruhan dataset, yaitu periode 1 s.d. 15

Gambar 6 menunjukkan hasil voting keunggulan model HC-2 (HIVE-COTE 2.0) dibandingkan dengan model Bi-RNN dalam memprediksi emiten yang masuk ke dalam daftar LQ 45 sehingga model tersebut direkomendasikan untuk investor jika kriteria yang diutamakan dalam memprediksi adalah mengurangi *false positive*. *False positive* sangatlah penting bagi investor untuk mengukur apakah prediksi perusahaan yang masuk LQ adalah memang bebas dari kesalahan.



Gambar. 7 Hasil voting untuk F1 score dari setiap model pada periode 1 s.d. 15

Gambar 7 menunjukkan hasil voting yang menyatakan keunggulan model MLP (*multi-layer perceptron*) dibandingkan dengan model-model lain dalam memprediksi emiten yang masuk ke dalam daftar LQ 45 sehingga model tersebut direkomendasikan jika kriteria yang diutamakan dalam memprediksi adalah keseimbangan antara *false positive* dan *false negative* yang hendak dikurangi tetapi bagi investor keseimbangan ini mungkin tidak begitu penting karena investor umumnya lebih tertarik untuk bagaimana mengurangi *false positive*.

Penjelasan yang melatarbelakangi model HIVE-COTE 2.0 mengungguli model-model lainnya adalah HIVE-COTE 2.0 menggunakan *Temporal Dictionary Ensemble* (TDE) yang mampu mempelajari pola-pola yang berulang dan hal ini memberikan keuntungan dibandingkan dengan model-model lainnya. Selain itu, HIVE-COTE 2.0 juga menggunakan *Diverse Representation Canonical Interval Forest* (DrCIF) yang secara acak memilih dimensi yang digunakan dalam setiap interval; keacakan ini mirip seperti pada *Random Forest* [31], model *bagging* yang secara umum memberikan keakuratan yang tinggi.

Sedangkan alasan yang melatarbelakangi mengapa model MLP (*multi-layer perceptron*) mengungguli prediksi emiten yang masuk ke dalam daftar LQ 45 didasarkan pada kapabilitas model yang memiliki kesempatan belajar yang tinggi oleh karena banyaknya *neuron* (512) pada satu *hidden layer*.

IV. KESIMPULAN

Penelitian ini meneliti tentang prediksi emiten-emiten yang akan masuk ke dalam daftar LQ 45 dengan menggunakan model-model *machine learning* dan *deep learning*. Masalah *time series classification* ini belum pernah diteliti sebelumnya sehingga hasil penelitian ini menjadi *baseline* bagi penelitian-penelitian berikutnya, khususnya model-model prediksi yang digunakan.

Hasil penelitian juga menemukan bahwa HIVE-COTE 2.0 yang merupakan model *state-of-the-art* untuk *time series classification* memberikan kinerja terbaik dalam memprediksi emiten-emiten, yaitu rata-rata keunggulan sekitar 9% dibandingkan model-model lainnya. Jika kriteria yang dipertimbangkan adalah mengurangi *false positive* yang memang diinginkan oleh investor, HIVE-COTE 2.0 merupakan pilihan yang tepat. Jika kriteria yang diutamakan adalah menjaga keseimbangan antara mengurangi *false positive* dan *false negative*, maka model *multi-layer perceptron* dengan banyak *neuron* yang cukup besar (512) memberikan kinerja yang lebih baik, yaitu rata-rata keunggulan 9% dibandingkan model-model yang lainnya.

UCAPAN TERIMA KASIH / ACKNOWLEDGMENT

Peneliti mengucapkan terimakasih kepada Universitas Kristen Maranatha yang telah memberikan dukungan dana yang mencukupi dalam menyelesaikan penelitian ini.

REFERENSI

- [1] Otoritas Jasa Keuangan, "Emiten." 2017.
- [2] Indonesia Stock Exchange, "Indeks Saham." 2021.
- [3] C. Brooks, *Introductory Econometrics for Finance 4th Edition*. Cambridge University Press, 2019.
- [4] Indonesia Stock Exchange, "Apa yang dimaksud saham LQ 45 dan apa yang menjadi kriteria?" 2021.
- [5] Indonesia Stock Exchange, *IDX Stock Index Handbook v1.2*. Indonesia Stock Exchange, 2021.
- [6] Y. Yulianti, N. Wahdi, and S. Saifudin, "MODEL PREDIKSI ARUS KAS MASA DEPAN PADA EMITEN LQ45 YANG TERDAFTAR DI BURSA EFEK INDONESIA," *Jurnal Dinamika Sosial Budaya*, vol. 17, no. 2, pp. 323–337, 2017.
- [7] R. Maulidia, A. W. Mahsun, and A. Afifudin, "KEMAMPUAN INFORMASI LABA DAN ARUS KAS DALAM MEMREDIKSI ARUS KAS MASA DEPAN (Studi Kasus Pada Perusahaan Di Bursa Efek Indonesia (BEI) Yang Terdaftar Dalam LQ-45 Periode 2014-2016)," *Jurnal Ilmiah Riset Akuntansi*, vol. 7, no. 09, 2018.
- [8] Y. Maharani, "Model Prediksi Arus Kas di Masa Depan (Studi Empiris pada Perusahaan Telekomunikasi yang Terdaftar di BEI)," *Jurnal Ilmu Sosial, Manajemen, Akuntansi dan Bisnis*, vol. 1, no. 1, pp. 1–13, 2020.
- [9] T. Hidayatulloh, "Kajian Komparasi Penerapan Algoritma Support Vector Machine (SVM) dan Multilayer Perceptron (MLP) Dalam Prediksi Indeks Saham Sektor Perbankan: Studi Kasus Saham LQ45 IDX Bank BCA," *SNIT 2014*, vol. 1, no. 1, pp. 262–272, 2014.
- [10] A. O. Indarso and A. B. Pangaribuan, "Penggunaan Metode Multilayer Perceptron Pada Prediksi Indeks Saham LQ45," *Informatik: Jurnal Ilmu Komputer*, vol. 17, no. 1, pp. 38–47, 2021.
- [11] A. B. Pangaribuan, A. Octa, and B. Hananto, "PENGUNAAN METODE MULTILAYER PERCEPTRON PADA PREDIKSI INDEKS SAHAM LQ45," *METHODIKA: Jurnal Teknik Informatika dan Sistem Informasi*, vol. 5, no. 1, pp. 24–29, 2019.
- [12] E. Patriya, "Implementasi Support Vector Machine Pada Prediksi Harga Saham Gabungan (IHSG)," *Jurnal Ilmiah Teknologi dan Rekayasa*, vol. 25, no. 1, pp. 24–38, 2020.
- [13] D. N. H. Hastuti and M. T. Jatipaningrum, "Perbandingan Metode Holt-Winter's Exponential Smoothing dan Weighted Fuzzy Integrated Time Series untuk Memprediksi LQ45," *Jurnal Statistika Industri dan Komputasi*, vol. 6, no. 2, pp. 102–112, 2021.
- [14] A. A. Kurniasi, M. A. Saptari, and others, "Aplikasi Peramalan Harga Saham Perusahaan Lq45 Dengan Menggunakan Metode Arima," *JURNAL SISTEM INFORMASI*, vol. 5, no. 1, 2021.
- [15] T. Indayani and M. Y. Darsyah, "Pemilihan Model Peramalan Terbaik Menggunakan Model Arima dan Winters Untuk Meramalkan Indeks LQ45," in *Prosiding Seminar Nasional Mahasiswa Unimus*, 2018, vol. 1.
- [16] R. Susanti and A. R. Adji, "ANALISIS PERAMALAN IHSG DENGAN TIME SERIES MODELING ARIMA," *Jurnal Manajemen Kewirausahaan*, vol. 17, no. 1, pp. 97–106, 2020.
- [17] D. Priyadi and I. Mardiyah, "MODEL AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (ARIMA) DALAM PERAMALAN NILAI HARGA SAHAM PENUTUP INDEKS LQ45," *Jurnal Ilmiah Informatika Komputer*, vol. 26, no. 1, pp. 78–94, 2021.
- [18] E. Eti, "PENDEKATAN METODE INDEKS TUNGGAL DALAM ANALISIS PEMBENTUKAN PORTOFOLIO OPTIMAL DARI SAHAM-SAHAM LQ45 PADA PERIODE WAKTU YANG BERBEDA," *Jurnal Akuntansi Bisnis*, vol. 3, no. 1, 2017.
- [19] Z. Puspitaningtyas, "Prediksi pergerakan harga saham menggunakan analisis profitabilitas," *Performance: Jurnal Personalia, Financial, Operasional, Marketing dan Sistem Informasi*, vol. 24, no. 2, pp. 29–35, 2017.
- [20] Y. Supriadi and M. Ariffin, "Pengaruh Kinerja Keuangan Terhadap Harga Saham," *Jurnal Ilmiah Manajemen Kesatuan*, vol. 1, no. 1, pp. 53–68, 2013.
- [21] W. Wei and D. P. Reilly, *Time Series Analysis: Univariate and Multivariate Methods*. Pearson Education, 1989.
- [22] K. P. Murphy, *Probabilistic Machine Learning: An introduction*. MIT Press, 2022. [Online]. Available: probml.ai
- [23] M. Schuster and K. K. Paliwal, "Bidirectional recurrent neural networks," *IEEE Transactions on Signal Processing*, vol. 45, no. 11, pp. 2673–2681, 1997, doi: 10.1109/78.650093.
- [24] F. Chollet, *Deep Learning with Python Second Edition*. Manning, 2021.
- [25] J. and F. M. and L. J. and B. A. and B. A. Middlehurst Matthew and Large, "HIVE-COTE 2.0: a new meta ensemble for time series classification," *Mach Learn*, vol. 110, no. 11, pp. 3211–3243, Dec. 2021, doi: 10.1007/s10994-021-06057-9.
- [26] A. Bostrom Aaron and Bagnall, "Binary Shapelet Transform for Multiclass Time Series Classification," in *Big Data Analytics and Knowledge Discovery*, 2015, pp. 257–269.
- [27] J. Brownlee, *Deep Learning for Time Series Forecasting. Machine Learning Mastery*, 2019.
- [28] S. Raschka, "Model evaluation, model selection, and algorithm selection in machine learning," *arXiv preprint arXiv:1811.12808*, 2018.
- [29] S. Raschka and V. Mirjalili, *Python machine learning: Machine learning and deep learning with Python, scikit-learn, and TensorFlow 2*. Packt Publishing Ltd, 2019.
- [30] A. Dempster, F. Petitjean, and G. I. Webb, "ROCKET: exceptionally fast and accurate time series classification using random convolutional kernels," *Data Min Knowl Discov*, vol. 34, no. 5, pp. 1454–1495, 2020.
- [31] L. Breiman, "Random forests," *Mach Learn*, vol. 45, pp. 5–32, 2001.