

BAB II

LANDASAN TEORI

2.1 Saham

2.1.1 Pengertian Saham

Saham merupakan salah satu yang banyak diminati oleh para investor di bursa efek (*stock exchange*). Saham dapat didefinisikan sebagai tanda atau pemilikan seseorang atau badan dalam suatu perusahaan atau perseroan terbatas dengan jangka waktu tidak terbatas. Saham berwujud selebar kertas yang menerangkan bahwa pemilik kertas adalah pemilik perusahaan yang menerbitkan surat berharga tersebut. Porsi kepemilikan ditentukan oleh seberapa besar penyertaan yang ditanamkan di perusahaan tersebut (Darmadji & Fakhruddin, 2011).

Saham dikenal dengan karakteristik “imbang hasil tinggi, resiko tinggi”. Artinya, saham merupakan surat berharga yang memberikan peluang keuntungan dan potensi resiko yang tinggi. Saham memungkinkan investor untuk mendapatkan imbalan hasil atau capital gain yang besar dalam waktu singkat. Namun seiring berfluktuasinya harga saham, maka saham juga dapat membuat investor mengalami kerugian besar dalam waktu singkat.

2.1.2 Harga Saham

Penilaian harga saham merupakan hal yang sangat penting dan mendasar bagi para investor sebelum melakukan investasi karena saham merupakan salah satu jenis investasi yang menjanjikan untuk para investor. Harga saham sangat

ditentukan dari penawaran dan permintaan akan saham itu sendiri (Rahmadewi & Abundanti, 2018).

Adapun jenis-jenis harga saham menurut (Widoatmodjo, 2005) adalah sebagai berikut:

1. Harga Nominal

Harga nominal merupakan harga yang tercantum dalam sertifikat saham, yang ditetapkan oleh emiten untuk menilai setiap lembar saham yang dikeluarkan. Besarnya harga nominal memberikan arti penting saham karena dividen minimal biasanya ditetapkan berdasarkan nilai nominal.

2. Harga Perdana

Harga perdana merupakan harga saham yang pertama kali dicatat oleh bursa efek, yang ditetapkan oleh penjamin emisi (underwrite) dan emiten. Dengan demikian akan diketahui berapa harga saham emiten itu akan dijual kepada masyarakat dan digunakan untuk menentukan harga perdana selanjutnya.

3. Harga Pasar

Harga pasar adalah harga saham yang telah dicatat di bursa efek pada saat itu, dengan kata lain harga pasar adalah harga jual dari investor yang satu dengan investor yang lain. Transaksi di sini tidak lagi melibatkan emiten dari penjamin emisi dan harga inilah yang benar-benar mewakili harga perusahaan penerbitnya.

4. Harga Pembukaan

Harga pembukaan adalah harga yang diminta oleh penjual atau pembeli pada saat jam bursa dibuka pada hari itu. Harga pembukaan bisa menjadi

harga pasar, begitu juga sebaliknya harga pasar mungkin juga akan menjadi harga pembukaan. Namun tidak selalu terjadi.

5. Harga Penutupan

Harga penutupan adalah harga yang diminta oleh penjual atau pembeli pada saat akhir hari bursa. Hari bursa ditutup pada sore hari tepat pada jam 16:00 WIB.

6. Harga Tertinggi

Harga tertinggi merupakan harga yang paling tinggi yang terjadi pada hari bursa. Harga ini bisa berubah lebih dari satu kali setiap harinya pada suatu saham.

7. Harga Terendah

Harga terendah merupakan harga yang paling rendah yang terjadi pada hari bursa. Harga ini bisa berubah lebih dari satu kali setiap harinya pada suatu saham. Dengan kata lain, harga terendah merupakan lawan dari harga tertinggi.

8. Harga Rata-Rata

Harga rata-rata merupakan perataan dari harga tertinggi dan terendah.

2.1.3 Analisis Harga Saham

Ada dua macam analisis dalam dunia saham, yaitu analisis fundamental dan analisis teknikal. Analisis fundamental adalah suatu metoda peramalan pergerakan instrumen finansial di waktu mendatang berdasarkan pada keadaan perekonomian, politik, lingkungan, dan faktor-faktor relevan lainnya, serta statistik yang akan mempengaruhi permintaan dan penawaran instrumen finansial tersebut. Analisis

fundamental mengidentifikasi dan mengukur faktor-faktor yang menentukan nilai intrinsik suatu instrumen finansial. Apabila penawaran meningkat tetapi permintaan tetap, maka harga pasar akan meningkat, begitu sebaliknya. Salah satu kesulitan analisis fundamental adalah mengukur secara akurat hubungan antara variable-variabel, sehingga para analis harus membuat estimasi berdasarkan pengalaman mereka. Sedangkan analisis teknikal adalah suatu metoda meramalkan pergerakan harga saham dan meramalkan kecenderungan pasar di masa mendatang dengan cara mempelajari grafik harga saham, volume perdagangan dan indeks harga saham gabungan. Analisis teknikal lebih memperhatikan pada apa yang telah terjadi di pasar, daripada apa yang seharusnya terjadi. Para analis teknikal tidak terlalu peduli terhadap faktor-faktor yang mempengaruhi pasar, sebagaimana para analis fundamental, tetapi lebih berkonsentrasi pada instrumen pasarnya (Susanto & Sabardi, 2010).

2.2 PT. Multipolar Technology

Berdiri pada tahun 1975, PT Multipolar Technology Tbk (MLPT) adalah System Integrator terkemuka di Indonesia, dan merupakan salah satu perusahaan pertama yang memperoleh sertifikasi ISO 9001. Tanggal 8 Juli 2013 merupakan momen bersejarah dalam rekam jejak PT Multipolar Technology Tbk, yang resmi tercatat di Bursa Efek Indonesia (BEI) dengan kode saham MLPT, dan terdaftar sebagai sekuritas syariah. Pemegang saham mayoritas Multipolar Technology adalah PT Multipolar Tbk (MLPL), perusahaan induk terkemuka yang berfokus pada segmen ritel dan TMT (Teknologi, Multimedia dan Telekomunikasi) dengan 80% kepemilikan saham; dan sisanya 20% dimiliki oleh publik.

Multipolar Technology adalah mitra terpercaya dari penyedia TI terkemuka di dunia seperti IBM, Cisco, NCR, VMware, Oracle, and Microsoft. Profesionalisme kami telah diakui dengan level kemitraan seperti IBM Premier Partner, Cisco Gold Partner, dan VMware Premier Partner (Multipolar Technology, 2019).

Di bawah ini adalah daftar anak perusahaan yang berada di bawah naungan Multipolar Technology.

Tabel 2.1 Daftar Anak Perusahaan naungan Multipolar Technology

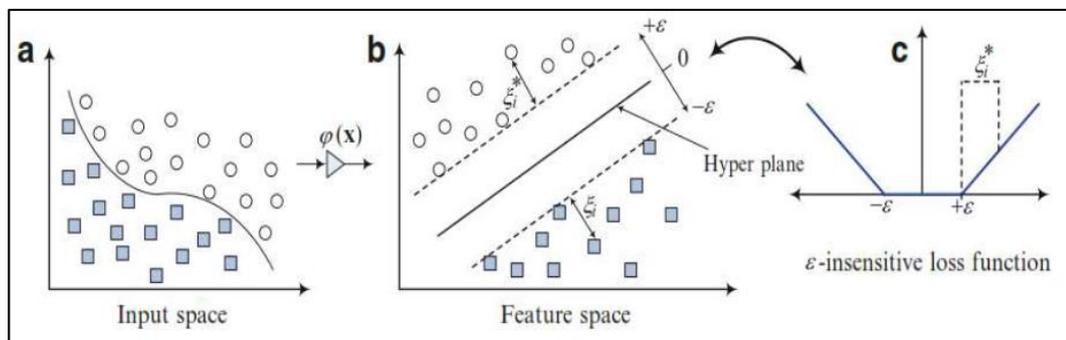
Anak perusahaan Multipolar Technology	Kegiatan bisnis
PT Visionet Data Internasional (VDI)	Menyediakan layanan <i>Field Operation Managed Services, Branch IT Services, Merchant IT Services, IT Operations Managed Services, IT Application Managed Services, Contact Center Services</i> , hingga <i>Digital Product Innovation</i> .
PT Graha Teknologi Nusantara (GTN)	Menyediakan layanan <i>Colocation Services, Integration Services, Data Center Managed Services</i> , hingga <i>IT Consultancy Services</i> .
PT Multi Solusi Andal (MSA)	Difokuskan buat memperluas jangkauan layanan TI.

2.3 Support Vector Regression (SVR)

Support Vector Regression (SVR) adalah suatu metode untuk mengestimasi sebuah fungsi yang dipetakan dari objek input ke jumlah riil berdasarkan data pelatihan. SVR merupakan bentuk penerapan yang paling umum dari *Support Vector Machine (SVM)* untuk kasus regresi sehingga dapat digunakan untuk peramalan layaknya metode regresi pada pendekatan statistik. Serupa dengan pengklasifikasian SVM, SVR memiliki properti yang sama tentang

memaksimalkan margin dan trik kernel untuk memetakan data yang nonlinier (Harafani, 2015).

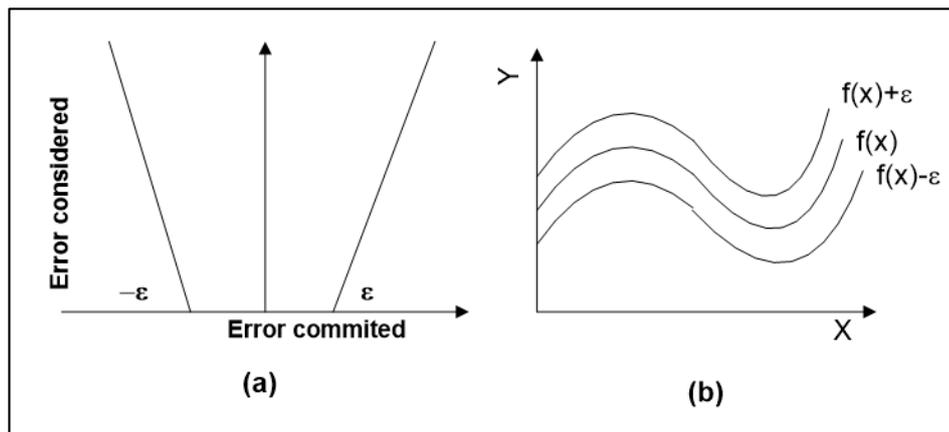
SVR merupakan metode yang dapat mengatasi *overfitting*, sehingga akan menghasilkan performansi yang baik (Fanani et al., 2019). *Overfitting* adalah perilaku data saat fase pelatihan atau *training* menghasilkan akurasi prediksi hampir sempurna. Tujuan dari SVR adalah untuk menemukan sebuah fungsi sebagai suatu *hyperplane* (garis pemisah) berupa fungsi regresi yang sesuai dengan semua input data dengan sebuah *error* ε dan membuat ε setipis mungkin (Scholkopf & Smola, 2002). *Hyperplane* terbaik dapat ditemukan dengan cara mengukur margin dengan *hyperplane* tersebut. Margin sendiri adalah jarak dari *hyperplane* dengan data yang terdekat. Data yang paling dekat dari margin disebut dengan *support*. (Smola & Scholkopf, 2004).



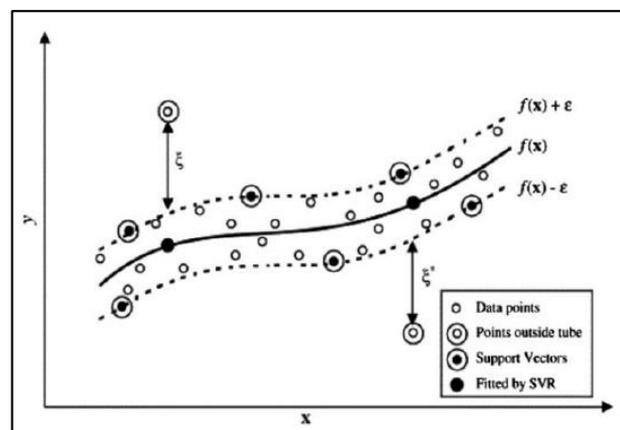
Gambar 2.1 Ilustrasi SVR 1 (Hong, 2013)

Metode SVR digunakan untuk mencari fungsi $f(x)$ yang mempunyai deviasi maksimal sebesar ε untuk mendapatkan target y_i dari semua data training (Caraka et al., 2017). Metode ini dapat bekerja pada permasalahan linear dan nonlinear dengan menggunakan konsep daerah ε -insensitive sebagai fungsi *symmetrical loss*. Besarnya nilai ε menentukan toleransi kesalahan antara nilai hasil prediksi dari

masukan dan nilai yang keluar sebenarnya dan mempengaruhi jumlah *support vector* (Awad & Khanna, 2015). SVR menentukan set data yang dibagi menjadi set *training* dan set validasi. Kemudian dari set *training* tersebut ditentukan suatu fungsi regresi dengan batasan deviasi tertentu sehingga dapat menghasilkan prediksi yang mendekati target actual.



Gambar 2.2 Ilustrasi SVR 2



Gambar 2.3 Ilustrasi SVR 3

Gambar 2.2(a) menunjukkan bagaimana *error* dalam SVR dihitung. Sampai dengan garis batas *error* ϵ , nilai *error* sama dengan 0, sedangkan di luar batas tersebut, nilai *error* dihitung sebagai *error-epsilon*. Sampai batas garis $(+\epsilon)$ dan $(-\epsilon)$, nilai *error* adalah 0 atau $\epsilon = 0$, sedangkan jika ada titik yang berada di luar margin

atau diluar tube (tabung) harus ditambahkan variabel slack ξ , sehingga nilai error merupakan error epsilon dan dikenai penalti sebesar C. Oleh karena itu, dari sebuah garis, akan dibentuk sebuah tabung yang memiliki toleransi terhadap *error* seperti yang ditunjukkan pada Gambar 2.2(b) (Cahyono et al., 2019).

Konsep SVR didasarkan pada *risk minimization*, yaitu untuk mengestimasi suatu fungsi dengan cara meminimalkan batas atas dari *generalization error*, sehingga SVR mampu mengatasi *overfitting*. Fungsi regresi tersebut akan sempurna apabila batas deviasinya sama dengan 0 sehingga dapat dituliskan sebagai berikut:

$$f(x) = w^T \varphi(x) + b \quad (1)$$

Dengan w merupakan vector pembobot, $\varphi(x)$ merupakan fungsi yang memetakan x dalam suatu dimensi dan b merupakan bias. (x) menunjukkan suatu titik didalam *feature space* F yang merupakan hasil pemetaan x didalam input space. Koefisien w dan b diestimasi dengan cara meminimalkan fungsi resiko (*risk function*) yang didefinisikan dalam persamaan (2) berikut :

$$\begin{aligned} & \min \frac{1}{2} \|w\|^2 C \frac{1}{\lambda} \sum_{i=1}^{\lambda} L_{\varepsilon}(y_i, f(x_i)) \\ & \text{subject to} \\ & \begin{cases} y_i - W\varphi(x_i) - b \leq \varepsilon \\ W\varphi(x_i) - y_i + b \leq \varepsilon, i = 1, 2, \dots, \lambda \end{cases} \\ & \text{Dimana :} \\ & L_{\varepsilon}(y_i, f(x_i)) = \begin{cases} |y_i - f(x_i)| - \varepsilon & |y_i - f(x_i)| \geq \varepsilon \\ 0 & \text{untuk yang lain} \end{cases} \end{aligned} \quad (2)$$

Faktor $\|w\|^2$ inilah yang dinamakan regularisasi. Meminimalkan $\|w\|^2$ akan membuat suatu fungsi setipis mungkin, sehingga bisa mengontrol kapasitas fungsi. Faktor lain yang dapat mendukung ketelitian fungsi ini adalah dengan memperhitungkan kesalahan empirik (*empirical error*) yang diukur dengan

besarnya ε -insensitive loss function. Nilai e mendefinisikan derajat toleransi terhadap *error*. Suatu fungsi dianggap layak dan baik apabila semua titik ada dalam rentang yang seharusnya, sebaliknya bila ada beberapa titik yang keluar dari rentang yang seharusnya maka fungsi tersebut tidak layak dilakukan untuk sebuah prediksi.

2.4 Particle Swarm Optimization (PSO)

Algoritma *Particle Swarm Optimization* (PSO) diperkenalkan oleh Kennedy dan Eberhart pada tahun 1995 (Kennedy & Eberhart, 1995). PSO telah ditemukan dengan menginspirasi perilaku sosial ikan atau burung untuk memecahkan masalah pengoptimalan global nonlinier (Kiran, 2017). PSO adalah salah satu dari teknik komputasi evolusioner, yang mana populasi pada PSO didasarkan pada penelusuran algoritma dan diawali dengan suatu populasi yang random yang disebut dengan partikel. PSO adalah algoritma optimasi stokastik berbasis populasi. Diketahui bahwa PSO mempertahankan dua populasi: populasi posisi partikel saat ini dan populasi posisi terbaik partikel yang dicapai hingga saat ini. Yang pertama dianggap sebagai solusi kandidat di ruang pencarian sementara yang kedua digunakan untuk memandu pembaruan sebelumnya. Dalam sistem PSO, setiap partikel dikaitkan dengan dua properti (vektor kecepatan V dan vektor posisi X) dan bergerak di ruang pencarian dengan kecepatan yang disesuaikan secara dinamis sesuai dengan pengalaman partikel dan pengalaman pengiring partikel secara bersamaan (Tian & Shi, 2018).

Berbeda dengan teknik komputasi evolusioner lainnya, setiap partikel di dalam PSO juga berhubungan dengan suatu *velocity*. Partikel tersebut bergerak melalui penelusuran ruang dengan *velocity* yang dinamis yang disesuaikan menurut perilaku historisnya. Oleh karena itu, partikel mempunyai kecenderungan untuk bergerak ke area penelusuran yang lebih baik setelah melewati proses penelusuran. PSO mempunyai kesamaan dengan *genetic algorithm* yang mana dimulai dengan suatu populasi yang random dalam bentuk matriks. Namun PSO tidak memiliki operator evolusi yaitu *crossover* dan mutasi seperti yang ada pada *genetic algorithm*. Baris pada matriks disebut partikel atau dalam *genetic algorithm* sebagai kromosom yang terdiri dari nilai suatu variabel. Setiap partikel berpindah dari posisinya semula ke posisi yang lebih baik dengan suatu *velocity* (Lubis, 2017).

2.5 Bagging

Bagging, atau *bootstrap aggregating*, adalah teknik klasik untuk pembuatan ansambel yang diusulkan oleh Breiman. Awalnya diusulkan untuk digunakan dalam masalah klasifikasi. Namun, dapat digunakan dalam masalah yang bertujuan untuk melakukan regresi data. Hal ini ditandai dengan pembuatan beberapa sampel, dengan penyesuaian kembali melalui teknik *bootstrap*, dari kumpulan data yang sama, sehingga dimungkinkan untuk membangun beberapa pohon berbeda untuk prediktor yang sama dan menggunakannya untuk menghasilkan prediksi agregat. Prediksi akhir dari proses ini dapat diperoleh dengan voting atau rata-rata, untuk masalah klasifikasi dan regresi masing-masing (Erdal & Karahanoglu, 2016). Ini memungkinkan pembuatan beberapa sampel untuk set yang sama. Keuntungan

menggunakan teknik ini untuk generasi ensemble adalah memungkinkan pengurangan kesalahan dalam prediktor dasar, yang dapat dianggap tidak stabil sebelum gangguan tertentu dan dapat memberikan perkiraan sendiri kinerja prediktif, yang berkorelasi dengan perkiraan *cross-validation* atau perkiraan set pengujian (Hamze-Ziabari & Bakhshpoori, 2018) (Ribeiro & dos Santos Coelho, 2020).

2.6 Root Mean Square Error (RMSE)

Root Mean Square Error (RMSE) merupakan besarnya tingkat kesalahan hasil prediksi, semakin kecil nilai RMSE maka hasil prediksi akan semakin akurat (Mahyudin et al., 2014). RMSE adalah metode pengukuran dengan mengukur perbedaan nilai dari prediksi sebuah model sebagai estimasi atas nilai yang diobservasi.

Metode RMSE diterapkan di Meteorologi untuk melihat seberapa efektif model perkiraan matematis tentang lingkungan di Atmosfer. Metode RMSE diterapkan di ekonomi untuk mengukur apakah model ekonomi sesuai dengan indikator ekonomi, pada Ilmu hidrologi RMSE digunakan untuk mengevaluasi kalibrasi (pengukuran standar) pada model bawah laut. Di dunia Industri, Metode RMSE digunakan untuk menilai akurasi metode peramalan/prediksi, apakah metode peramalan/prediksi tersebut sesuai atau tidak digunakan untuk memperkirakan permintaan di masa mendatang.

Cara Menghitung Root Mean Square Error (RMSE) adalah dengan mengurangi nilai aktual dengan nilai peramalan kemudian dikuadratkan dan

dijumlahkan keseluruhan hasilnya kemudian dibagi dengan banyaknya data. Hasil perhitungan tersebut selanjutnya dihitung kembali untuk mencari nilai dari akar kuadrat seperti pada persamaan (3) sebagai berikut:

$$\text{RMSE} = \left(\frac{\sum (y_i - \hat{y}_i)^2}{n} \right)^{1/2} \quad (3)$$

Keterangan:

RMSE = nilai root mean square error

y = nilai aktual

\hat{y} = nilai hasil prediksi

i = urutan data pada database

n = jumlah data

2.7 Penelitian Terkait

Penelitian ini dilakukan tidak terlepas dari hasil penelitian-penelitian terdahulu yang pernah dilakukan sebagai bahan perbandingan dan kajian. Penelitian terdahulu memudahkan penulis dalam menentukan langkah-langkah untuk penyusunan penelitian dari segi teori maupun konsep.

Berikut merupakan penelitian terdahulu berupa beberapa jurnal terkait dengan penelitian yang dilakukan:

Tabel 2.2 Penelitian Terkait

No	Penulis dan Tahun Penelitian	Judul	Metode	Hasil
1	(Fadilah et al., 2020)	Analisis Prediksi Harga Saham Pt. Telekomunikasi Indonesia Menggunakan Metode Support Vector Machine	SVM (Support Vector Machine) Dan KNN (K-Nearest Neighbor)	Dari hasil pengujian dengan metode Support Vector Machine dihasilkan tingkat akurasi sebesar 0.9641 dan RMSE sebesar 0.0932. Pengujian juga dilakukan menggunakan algoritma k-Nearest Neighbors dengan tingkat akurasi sebesar 0.945 dan RMSE sebesar 0.1162. Dengan itu diketahui bahwa algoritma SVM memiliki tingkat akurasi yang lebih tinggi dan tingkat error yang lebih rendah dibandingkan metode KNN.

Tabel 2.2 Penelitian Terkait (Lanjutan 1)

No	Penulis dan Tahun Penelitian	Judul	Metode	Hasil
2	(Rusyida & Pratama, 2020)	Prediksi Harga Saham Garuda Indonesia Di Tengah Pandemi Covid-19 Menggunakan Metode ARIMA	ARIMA (Autoregresif Integrated Moving Average)	Dari hasil penelitian dengan menggunakan model ARIMA (3,1,2) menunjukkan bahwa data 22 April 2019 sampai 20 April 2020 dapat digunakan untuk memprediksi harga tutup saham 21 April 2020 sampai 13 Juli 2020. Model ARIMA terbaik yang diperoleh adalah ARIMA (3,1,2) harga saham PT. Garuda Indonesia, Tbk hari ini dipengaruhi oleh satu hari perdagangan yang lalu. Prediksi harga saham harian PT. Garuda Indonesia, Tbk di Bursa Efek Indonesia dari 21 April 2020 sampai 13 Juli 2020 cenderung mengalami penurunan
3	(Satyo et al., 2020)	Optimais Deep Learning Untuk Prediksi Data Saham Di Era Pandemi Covid-19	LTSM (Long short-term memory) dan	3 saham bank yang mempunyai reputasi bagus dan korelasi yang tinggi, yaitu : Bank Central Asia, Bank Rakyat Indonesia, dan Bank Mandiri. Dengan

Tabel 2.2 Penelitian Terkait (Lanjutan 2)

No	Penulis dan Tahun Penelitian	Judul	Metode	Hasil
			GRI (Gated Recurrent Unit).	menggunakan data dengan jumlah besar seperti data saham bank yang dipergunakan dalam penelitian ini. Menunjukkan dari 3 data tersebut bahwa GRU mempunyai kemampuan yang jauh lebih baik dibandingkan STM.
4	(Maulana & Kumalasari, 2019)	Analisis Dan Perbandingan Algoritma Data Mining Dalam Prediksi Harga Saham Ggrm	Neural Network, Linear Regression, Support Vector Machine, Gaussian Process, dan Polynomial Regression.	Hasil penelitian ini menyimpulkan bahwa data harga saham GGRM dapat diprediksi dengan menggunakan model algoritma Neural Network, dengan hasil akurasi prediksi RMSE 612.474 +/- 89.402 (mikro: 618.916 +/- 0.000) paling kecil dibandingkan dengan model algoritma lainnya.

Tabel 2.2 Penelitian Terkait (Lanjutan 3)

No	Penulis dan Tahun Penelitian	Judul	Metode	Hasil
5	(Ramadhan et al., 2019)	Optimasi Parameter Model Autoregressive Menggunakan Algoritma Particle Swarm Optimization	Autoregressive dan PSO (Particle Swarm Optimization)	Hasil Peramalan PT Perusahaan Gas Negara untuk 30 periode kedepan, yaitu dari tanggal 26 Januari 2018 sampai dengan 24 Februari 2018 mengalami fluktuasi. Dengan perhitungan menggunakan Microsoft Excel 2013 memperoleh nilai MAPE in-sample sebesar 0,988 dan out-sample sebesar 5,149 yang artinya kedua nilai MAPE tersebut mempunyai kinerja bagus
6	(Oktavianti et al., 2019)	Analisis Pola Prediksi Data Time Series menggunakan Support Vector Regression, Multilayer Perceptron, dan Regresi Linear Sederhana	Support Vector Regression, Multilayer Perceptron (MLP), dan Regresi Linear Sederhana	Menunjukkan bahwa untuk Dataset 1, ANN-Multilayer Perceptron memiliki kinerja yang lebih baik daripada SVR dengan nilai MSE, MAE dan RMSE adalah 251.09, 11.45, dan 15.84. Kemudian untuk Dataset 2, SVRLinear memiliki kinerja lebih baik dibandingkan MLP dengan nilai MSE, MAE dan RMSE sebesar 1839.93, 32.80, dan 42.89. Dataset

Tabel 2.2 Penelitian Terkait (Lanjutan 4)

No	Penulis dan Tahun Penelitian	Judul	Metode	Hasil
				yang digunakan untuk prediksi jumlah perizinan adalah dataset 2
7	(Raharyani et al., 2018)	Implementasi Algoritme Support Vector Regression Pada Prediksi Jumlah Pengunjung Pariwisata	Support Vector Regression	Hasil pengujian menunjukkan bahwa rata-rata nilai MAPE minimum yang dihasilkan adalah 9,16% dan nilai MAPE terbaik yang didapatkan adalah 6,98% yang berarti rata-rata selisih antara hasil prediksi dengan data aktual sebesar 115 jumlah pengunjung dengan parameter $\sigma = 925,8409$ $\lambda = 0,3868$, $cLR = 0,0802$, $\epsilon = 1,27E-10$, $complexity = 3234,539$, jumlah iterasi maksimal 5000.
8	(Rusmalawati et al., 2018)	Peramalan Harga Saham Menggunakan Metode Support Vector Regression	SVR dan PSO	Hasil penelitian didapatkan nilai MAPE sebesar 0,8195% dengan fitness 0,5496 dapat disimpulkan bahwa hasil peramalan menggunakan SVRPSO memiliki akurasi tinggi karena kurang dari 10%.

Tabel 2.2 Penelitian Terkait (Lanjutan 5)

No	Penulis dan Tahun Penelitian	Judul	Metode	Hasil
9	(Shobary, 2018)	Optimasi Pengembangan Biaya Software Dengan Perbandingan Neural Network Dengan Optimasi Algoritma Genetika Dan Bagging	Neural Network (NN), Algoritma Genetika Dan Bagging	NN didapatkan nilai RMSE terkecil adalah 0,056, neural network dan bagging didapatkan nilai RMSE terkecil adalah 0,049, neural network dan algoritma genetika didapatkan nilai RMSE terkecil adalah 0,036 dan gabungan ketiga model neural network, algoritma genetika dan bagging didapatkan nilai rata-rata RMSE adalah 0,035 dan nilai RMSE terkecil adalah 0,033. gabungan ketiga metode lebih akurat dibanding dengan metode individual neural network.
10	(Febrianto et al., 2018)	Pemodelan Regresi Linear Untuk Prediksi Konsumsi Energi Primer Indonesia Menggunakan Hybrid Particle Swarm Optimization Dan Continuous Ant Colony	Regresi Linear Berganda Hybrid Particle Swarm Optimization Dan Continuous	Dari hasil perbandingan antara regresi linear-PSOACOR dengan regresi linear-PSO dan regresi linear-ACOR mendapati bahwa regresi linear-PSOACOR tidak lebih baik daripada regresi linear-PSO biasa dari sisi hasil MAPE pada data uji maupun dari waktu komputasi.

Tabel 2.2 Penelitian Terkait (Lanjutan 6)

No	Penulis dan Tahun Penelitian	Judul	Metode	Hasil
		Optimization	Ant Colony Optimization	
11	(Noor, 2018)	Perbandingan Algoritma Support Vector Machine Biasa Dan Support Vector Machine Berbasis Particle Swarm Optimization Untuk Prediksi Gempa Bumi	Support Vector Machine (SVM) dan Particle Swarm Optimization (PSO)	Algoritma Support Vector Machines hasilnya lebih rendah RMSE nya dibandingkan dengan Support Vector Machines Berbasis PSO. RMSE untuk <i>Support Vector Machines</i> adalah 9.720. Sedangkan Hasil RMSE Support Vector Machines Berbasis PSO adalah 37.685
12	(Bonita et al., 2018)	Prediksi Harga Batu Bara Menggunakan Support Vector Regression (SVR)	Support Vector Regression (SVR) menggunakan kernel Gaussian RBF dan kernel ANOVA	SVR memberikan hasil paling optimal saat memprediksi harga 1 bulan berikutnya. Hasil prediksi dari kedua kernel memiliki perbedaan yang tidak terlalu besar, tetapi kernel ANOVA bekerja lebih baik pada data harga batu bara.

Tabel 2.2 Penelitian Terkait (Lanjutan 7)

No	Penulis dan Tahun Penelitian	Judul	Metode	Hasil
13	(Lubis, 2017)	Metode Hybrid Particle Swarm Optimization - Neural Network Backpropagation Untuk Prediksi Hasil Pertandingan Sepak Bola	Particle Swarm Optimization (PSO) dan Neural Network (NN)	Dengan menggunakan metode optimasi (Particle Swarm Optimization) Rata-rata error sebesar 0.001, sedangkan pada metode sebelum dilakukan tahapan optimasi error yang didapat sebesar 0.004. Hasil menunjukkan bahwa dengan menggunakan metode Optimasi (Particle Swarm Optimization) hasil yang diperoleh akan lebih baik daripada metode sebelumnya.
14	(Usman, 2017)	Prediksi Harga Lada Dengan Menggunakan Neural Network Berbasis Particle Swarm Optimization	Backpropagation Neural Network (BPPN) dan Particle swarm optimization (PSO)	Diperoleh model terbaik pada Backpropagation Neural Network (BPPN) menghasilkan nilai RMSE yang lebih baik yaitu 0.084 dibandingkan dengan hanya menggunakan BPNN saja yaitu 0.096. Hal ini membuktikan bahwa dengan metode PSO mampu memberikan hasil yang lebih baik.

Tabel 2.2 Penelitian Terkait (Lanjutan 8)

No	Penulis dan Tahun Penelitian	Judul	Metode	Hasil
15	(Zyen & Kusumodestoni, 2016)	Pengembangan Model Prediksi Harga Saham Berbasis Neural Network	Neural Network	Menggunakan satu set data 132 hasil tren akurasi prediksi 0.456 +/- 0,044 dan menggunakan data set 256 akurasi prediksi meningkat menjadi 0481 +/- 0169, kita dapat menyimpulkan bahwa dengan menggunakan satu set data yang lebih maka dapat meningkatkan akurasi prediksi nilai trend yang dibuktikan dengan waktu percobaan pertama untuk menggunakan data sebanyak 132 dan pada kedua mencoba untuk menggunakan data sebanyak akurasi prediksi 256 tren meningkat 2,5% yaitu 0,025 +/- 0,125.

2.8 Matriks Penelitian

Matriks penelitian atau *State of the art* menjelaskan hubungan penelitian terdahulu yang terkait dengan penelitian yang dilakukan. Dalam matrik penelitian ini menunjukkan menunjukkan pendekatan yang berbeda-beda dalam menemukan sebuah solusi.

Berikut matrik penelitian tertera pada Tabel 2.3

Tabel 2.3 Matriks Penelitian

No	Penulis / Tahun	Lingkup Penelitian										
		Metode							Optimasi			
		Neural Network	Support Vector Regression	Support Vector Machine	Regresi Linier	ARIMA	LSTM	K-NN	Algoritma Genetika	Bagging	Particle Swarm Optimization	Continuous Ant Colony Optimization
1	(Zyen & Kusumodestoni, 2016)	✓	-	-	-	-	-	-	-	-	-	-
2	(Usman, 2017)	✓	-	-	-	-	-	-	-	-	✓	-
3	(Lubis, 2017)	✓	-	-	-	-	-	-	-	-	✓	-
4	(Bonita et al., 2018)	-	✓	-	-	-	-	-	-	-	-	-
5	(Noor, 2018)	-	-	✓	-	-	-	-	-	-	✓	-
6	(Febrianto et al., 2018)	-	-	-	✓	-	-	-	-	-	✓	✓
7	(Shobary, 2018)	✓	-	-	-	-	-	-	✓	✓	-	-

Tabel 2.3 Matriks Penelitian (Lanjutan 1)

No	Penulis / Tahun	Lingkup Penelitian										
		Metode						Optimasi				
		Neural Network	Support Vector Regression	Support Vector Machine	Regresi Linier	ARIMA	LSTM	K-NN	Algoritma Genetika	Bagging	Particle Swarm Optimization	Continuous Ant Colony Optimization
8	(Rusmalawati et al., 2018)	-	✓	-	-	-	-	-	-	-	✓	-
9	(Raharyani et al., 2018)	-	✓	-	-	-	-	-	-	-	-	-
10	(Oktavianti et al., 2019)	✓	✓	-	✓	-	-	-	-	-	-	-
11	(Ramadhan et al., 2019)	-	-	-	-	✓	-	-	-	-	✓	-
12	(Maulana & Kumalasari, 2019)	✓	-	✓	✓	-	-	-	-	-	-	-
13	(Satyo et al., 2020)	-	-	-	-	-	✓	-	-	-	-	-
14	(Rusyida & Pratama, 2020)	-	-	-	-	✓	-	-	-	-	-	-
15	(Fadilah et al., 2020)	-	-	✓	-	-	-	✓	-	-	-	-
16	(Sheila Maulida Intani, 2021)	-	✓	-	-	-	-	-	-	✓	✓	-