

**PREDIKSI HARGA SAHAM MENGGUNAKAN MODEL ARTIFICIAL
NEURAL NETWORK (ANN) BERBASIS DATA TIME SERIES DAN
SENTIMEN PASAR**

TESIS

**Oleh:
MUHAMMAD KHOZIN
NIM. 220605210017**



**MAGISTER TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2025**

**PREDIKSI HARGA SAHAM MENGGUNAKAN MODEL ARTIFICIAL NEURAL
NETWORK (ANN) BERBASIS DATA TIME SERIES DAN SENTIMEN PASAR**

THESIS

**Diajukan Kepada:
Universitas Islam Negeri Maulana Malik Ibrahim
Untuk Memenuhi Salah Satu Persyaratan dalam
Memperoleh Gelar Magister Komputer (M.Kom)**

**Oleh:
MUHAMMAD KHOZIN
NIM. 220605210017**

**PROGRAM STUDI MAGISTER INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2025**

**PREDIKSI HARGA SAHAM MENGGUNAKAN MODEL ARTIFICIAL NEURAL
NETWORK (ANN) BERBASIS DATA TIME SERIES DAN SENTIMEN PASAR**

THESIS

**Diajukan Kepada:
Universitas Islam Negeri Maulana Malik Ibrahim
Untuk Memenuhi Salah Satu Persyaratan dalam
Memperoleh Gelar Magister Komputer (M.Kom)**

**Oleh:
MUHAMMAD KHOZIN
NIM. 220605210017**

**PROGRAM STUDI MAGISTER INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2025**

**PREDIKSI HARGA SAHAM MENGGUNAKAN MODEL ARTIFICIAL NEURAL
NETWORK (ANN) BERBASIS DATA TIME SERIES DAN SENTIMEN PASAR**

THESIS

Oleh:
MUHAMMAD KHOZIN
NIM. 220605210017

Telah diperiksa dan disetujui untuk diuji:
Tanggal: 3 Desember 2025

Pembimbing I



Dr. Zainal Abidin, M. Kom
NIP. 19760613 200501 1 004

Pembimbing II



Dr. Totok Chamidy, M. Kom
NIP. 19691222-200604 1 001

Mengetahui,
Ketua Program Studi Magister Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang



Prof. Dr. Muhammad Faisal, M.T
NIP. 19740510 200501 1 007

PREDIKSI HARGA SAHAM MENGGUNAKAN MODEL ARTIFICIAL NEURAL NETWORK (ANN) BERBASIS DATA TIME SERIES DAN SENTIMEN PASAR

THESIS

Oleh:
MUHAMMAD KHOZIN
NIM. 220605210017

Telah dipertahankan di Depan Dewan Penguji Thesis
dan dinyatakan diterima sebagai salah satu persyaratan
untuk memperoleh gelar Magister Komputer (M.Kom)
Tanggal: 3 Desember 2025

Susunan Dewan Penguji

Penguji I	: <u>Dr. Ririen Kusumawati, M.Kom</u> NIP. 19720309 200501 2 002
Penguji II	: <u>Dr. M. Ainul Yaqin, M.Kom</u> NIP. 19761013 200604 1 004
Pembimbing I	: <u>Dr. Zainal Abidin, M. Kom</u> NIP. 19760613 200501 1 004
Pembimbing II	: <u>Dr. Totok Chamidy, M. Kom</u> NIP. 19691222 200604 1 001

Tanda Tangan

()
()
()
()

Mengetahui,
Ketua Program Studi Magister Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang



Prof. Dr. Muhammad Faisal, M.T
NIP. 19740510 200501 1 007

PERNYATAAN KEASLIAN TULISAN

Saya yang bertanda tangan di bawah ini:

Nama : MUHAMMAD KHOZIN
NIM : 220605210017
Program Studi : Magister Informatika
Fakultas : Sains dan Teknologi

Menyatakan dengan sebenarnya bahwa Thesis yang saya tulis ini benar-benar merupakan hasil karya saya sendiri, bukan merupakan pengambilalihan data, tulisan atau pikiran orang lain yang saya akui sebagai hasil tulisan atau pikiran saya sendiri, kecuali dengan mencantumkan sumber cuplikan pada daftar pustaka.

Apabila di kemudian hari terbukti atau dapat dibuktikan Thesis ini hasil jiplakan, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Malang, 12 Desember 2025

Yang membuat pernyataan



MUHAMMAD KHOZIN

NIM. 220605210017

MOTTO

Ilmu tanpa adab kehilangan makna, adab dengan ilmu melahirkan keberkahan

HALAMAN PERSEMBAHAN

Dengan segala kerendahan hati dan rasa syukur yang mendalam ke hadirat Allah SWT, Tuhan semesta alam, saya mempersembahkan tesis ini kepada pihak-pihak yang memiliki kontribusi besar dalam perjalanan akademik dan pribadi saya.

1. Kepada seluruh anggota keluarga tercinta, yang tidak pernah berhenti memberikan doa, dukungan moral, serta semangat yang menguatkan di setiap langkah. Kehadiran mereka menjadi sumber inspirasi sekaligus motivasi terbesar bagi saya untuk terus berjuang hingga tesis ini terselesaikan dengan baik.
2. Kepada seluruh Civitas Akademika Universitas Islam Negeri Maulana Malik Ibrahim Malang, yang telah memberikan ilmu, pengalaman, bimbingan, dan berbagai wawasan berharga sepanjang proses studi. Setiap arahan dan kesempatan belajar yang diberikan sangat berarti dalam pembentukan cara berpikir dan perkembangan akademik saya.
3. Kepada seluruh mahasiswa Magister Informatika Fakultas Sains dan Teknologi UIN Maulana Malik Ibrahim Malang, yang telah menjadi teman berdiskusi, berbagi gagasan, memberikan masukan konstruktif, serta saling menguatkan selama proses penyusunan tesis ini. Kebersamaan dan kolaborasi tersebut menjadi bagian penting dari perkembangan karya ilmiah ini.
4. Kepada Bapak, Ibu, Saudara, serta rekan-rekan lainnya yang tidak dapat saya sebutkan satu per satu, namun telah memberikan bantuan, dorongan, doa, dan perhatian dalam berbagai bentuk sehingga penelitian dan penyusunan tesis ini dapat diselesaikan dengan baik.
5. Kepada seluruh rekan Asosiasi Mahasiswa Magister Informatika Fakultas Sains dan Teknologi UIN Maulana Malik Ibrahim Malang dari seluruh angkatan, atas kerja sama, kolaborasi, dan kebersamaan yang terjalin selama ini. Dukungan tersebut memberikan suasana akademik yang positif serta memperkaya proses pembelajaran selama menempuh studi magister.

KATA PENGANTAR

Assalamu 'alaikum warahmatullahi wabarakatuh

Segala puji dan syukur senantiasa penulis haturkan ke hadirat Allah SWT, Tuhan Yang Maha Esa, karena dengan limpahan rahmat, hidayah, dan karunia-Nya, penulis dapat menyelesaikan seluruh rangkaian studi pada Program Studi Magister Informatika, Fakultas Sains dan Teknologi, Universitas Islam Negeri Maulana Malik Ibrahim Malang. Berkat izin-Nya pula, penyusunan tesis ini dapat diselesaikan dengan baik meskipun melalui berbagai proses dan tantangan.

Penulis menyadari sepenuhnya bahwa keberhasilan dalam penyusunan tesis ini tidak lepas dari dukungan, bantuan, serta kontribusi banyak pihak. Oleh karena itu, pada kesempatan yang terhormat ini penulis ingin menyampaikan apresiasi dan ucapan terima kasih yang sebesar-besarnya kepada:

1. Bapak Dr. Zainal Abidin, M. Kom., dan Bapak Dr. Totok Chamidy, M. Kom., selaku pembimbing tesis, yang telah berkenan meluangkan waktu, memberikan arahan, masukan, serta pengalaman berharga selama proses penyusunan hingga tesis ini mencapai bentuk akhirnya. Bimbingan dan perhatian beliau berdua sangat berarti dalam mengarahkan penulis untuk menghasilkan karya ilmiah yang lebih matang.
2. Seluruh sivitas akademika Program Studi Magister Informatika, khususnya para Bapak dan Ibu Dosen, atas segala ilmu, wawasan, motivasi, serta bimbingan yang diberikan selama penulis menempuh pendidikan. Segala pengetahuan dan pengalaman akademik yang telah diperoleh menjadi fondasi penting dalam penyelesaian tesis ini.
3. Rekan-rekan seperjuangan, yang senantiasa memberikan dukungan, doa, semangat, serta bantuan dalam proses penyusunan tesis. Kebersamaan, diskusi, dan saling menguatkan menjadi bagian yang tidak terpisahkan dari perjalanan ini.

Penulis menyadari sepenuhnya bahwa tesis ini masih memiliki keterbatasan dan jauh dari sempurna. Namun demikian, penulis berharap karya ini dapat memberikan manfaat bagi para pembaca, serta menjadi pengalaman berharga bagi penulis secara pribadi dalam menapaki perjalanan akademik ke depan. Aamiin yaa Rabbal 'Alamin.

Wassalamu 'alaikum warahmatullahi wabarakatuh

DAFTAR ISI

	Halaman
TITLE	i
PERNYATAAN KEASLIAN TULISAN	vi
MOTTO	vii
HALAMAN PERSEMBAHAN	viii
KATA PENGANTAR	ix
DAFTAR ISI.....	x
DAFTAR TABEL.....	xiii
DAFTAR GAMBAR.....	xv
ABSTRAK.....	xviii
ABSTRACT.....	xix
الملخص.....	xx
BAB I PENDAHULUAN	1
1. 1 Latar Belakang.....	1
1. 2 Pernyataan masalah.....	8
1. 3 Tujuan penelitian	8
1. 4 Batasan masalah.....	8
1. 5 Manfaat Penelitian	9
BAB II STUDI PUSTAKA	10
2. 1 Model ANN untuk Prediksi Harga Saham.....	10
2. 2 Kerangka Teoritis.....	15
BAB III DESAIN PENELITIAN.....	21
3. 1 Prosedur Penelitian	21
3.1. 1 Pengumpulan Data.....	22
3.1. 2 Rekayasa Data.....	24
3.1. 3 Desain sistem	28
3.1.3. 1 Ekstraksi Fitur.....	36
3.1. 4 Implementasi Sistem.....	37
3.1. 5 Eksperimen	37

3. 2	Research Instrument.....	39
BAB IV	MODEL ANN-BACKPROPAGATION DENGAN SENTIMEN	40
4. 1	Desain	40
4. 2	Implementasi.....	43
4. 3	Eksperimen	44
4.3.1	Ekperimen BPNNS-A1	45
4.3.2	Ekperimen BPNNS-A1-R.....	47
4.3.3	Ekperimen BPNNS-A1-L	49
4.3.4	Ekperimen BPNNS-A1-LR1	51
4.3.5	Ekperimen BPNNS-A1-LR3	53
4.3.6	Ekperimen BPNNS-A2.....	55
4.3.7	Ekperimen BPNNS-A2-R.....	57
4.3.8	Ekperimen BPNNS-B1	59
4.3.9	Ekperimen BPNNS-B1-L	61
4.3.10	Ekperimen BPNNS-B2	63
4.3.11	Ekperimen BPNNS-C1	65
4.3.12	Ekperimen BPNNS-C2	67
4.3.13	Ekperimen BPNNS-D1	69
4.3.14	Ekperimen BPNNS-D2	71
4. 4	Hasil Prediksi Dengan Sentimen	73
4. 5	Eksperimen Dengan Sentimen Berdasarkan Karakteristik Data	75
4.5.1	Ekperimen BPNNS-TN	76
4.5.2	Ekperimen BPNNS-TD	78
4.5.3	Hasil Prediksi Dengan Sentimen Berdasarkan Karakteristik Data	80
4. 6	Kesimpulan	82
BAB V	MODEL ANN-BACKPROPAGATION TANPA SENTIMEN	84
5. 1	Desain	84
5. 2	Implementasi.....	85
5. 3	Eksperimen	86
5.3.1	Eksperimen BPNN-A1.....	88
5.3.2	Eksperimen BPNN-A1-R.....	90

5.3.3	Eksperimen BPNN-A1-L.....	92
5.3.4	Eksperimen BPNN-A1-LR1	94
5.3.5	Eksperimen BPNN-A1-LR3	96
5.3.6	Eksperimen BPNN-A2.....	98
5.3.7	Eksperimen BPNN-A2-R.....	100
5.3.8	Eksperimen BPNN-B1	102
5.3.9	Eksperimen BPNN-B1-L	104
5.3.10	Eksperimen BPNN-B2.....	106
5.3.11	Eksperimen BPNN-C1	108
5.3.12	Eksperimen BPNN-C2.....	110
5.3.13	Eksperimen BPNN-D1.....	112
5.3.14	Eksperimen BPNN-D2.....	114
5. 4	Hasil Prediksi Tanpa Sentimen.....	116
5. 5	Eksperimen Tanpa Sentimen Berdasarkan Karakteristik Data	118
5.5.1	Eksperimen BPNN-TN	119
5.5.2	Eksperimen BPNN-TD	121
5.5.3	Hasil Prediksi Tanpa Sentimen Berdasarkan Karakteristik Data	123
5. 6	Kesimpulan	124
BAB VI	PEMBAHASAN	126
6. 1	Hasil dan Pembahasan	126
6. 2	Integrasi Sains dan Islam	138
BAB VII	KESIMPULAN.....	141
7.1	Kesimpulan	141
7.2	Keterbatasan dan saran	142
REFERENSI	144

DAFTAR TABEL

Tabel 2. 1 Ringkasan penelitian terdahulu.....	14
Tabel 2. 2 Performa algoritma dalam memprediksi harga saham	17
Tabel 3. 1 Data time series harga saham ADMR.....	23
Tabel 3. 2 Data sentiment pasar saham ADMR.....	23
Tabel 3. 3 Deskripsi data harga dan sentiment pasar Saham ADMR.....	24
Tabel 3. 4 Hasil pembersihan dan pelebelan data sentimen	25
Tabel 3. 5 Hasil perhitungan data sentimen (merata-ratakan)	25
Tabel 3. 6 Hasil penggabungan data harga saham dan sentimen pasar ADMR	27
Tabel 3. 7 Data harga saham setelah dinormalisasi	27
Tabel 3. 8 Detail data harga saham dan sentimen pasar ADMR	29
Tabel 3. 9 Penyaringan fitur kunci.....	36
Tabel 3. 10 Skenario Eksperimen Model ANN	37
Tabel 3. 11 Variabel penelitian.....	39
Tabel 4. 1 Parameter model prediksi harga saham ADMR	44
Tabel 4. 2 Eksperimen skenario pertama.....	44
Tabel 4. 3 Proses eksperimen BPNNS-A1	46
Tabel 4. 4 Proses eksperimen BPNNS- A1-R	48
Tabel 4. 5 Proses pelatihan eksperimen BPNNS-A1-L	50
Tabel 4. 6 Proses eksperimen BPNNS-A1-LR1	52
Tabel 4. 7 Proses pelatihan eksperimen BPNNS-A1-LR3	54
Tabel 4. 8 Proses pelatihan eksperimen BPNNS-A2.....	56
Tabel 4. 9 Proses pelatihan eksperimen BPNNS-A2-R.....	58
Tabel 4. 10 Proses pelatihan eksperimen BPNNS-B1	60
Tabel 4. 11 Proses eksperimen BPNNS-B1-L.....	62
Tabel 4. 12 Proses eksperimen BPNNS-B2.....	64
Tabel 4. 13 Proses eksperimen BPNNS-C1.....	66
Tabel 4. 14 Proses eksperimen BPNNS-C2.....	68
Tabel 4. 15 Proses eksperimen BPNNS-D1	70
Tabel 4. 16 Proses eksperimen BPNNS-D2	72

Tabel 4. 17 Ringkasan hasil prediksi model BPNN dengan data sentimen.....	74
Tabel 4. 18 Skenario eksperimen dengan sentimen berdasarkan karakteristik data.....	76
Tabel 4. 19 Proses eksperimen BPNN-TN.....	76
Tabel 4. 20 Proses eksperimen BPNN-TD.....	78
Tabel 4. 21 Ringkasan hasil prediksi BPNN dengan sentimen berdasarkan karakteristik data ...	80
Tabel 5. 1 Parameter model prediksi harga saham ADMR.....	86
Tabel 5. 2 Eksperimen skenario kedua.....	87
Tabel 5. 3 Pengolahan eksperimen BPNN-A1.....	88
Tabel 5. 4 Proses eksperimen BPNN-A1-R.....	90
Tabel 5. 5 Proses eksperimen BPNN-A1-L.....	92
Tabel 5. 6 Proses eksperimen BPNN-A1-LR1.....	94
Tabel 5. 7 Proses eksperimen BPNN-A1-LR3.....	96
Tabel 5. 8 Proses eksperimen BPNN-A2.....	98
Tabel 5. 9 Proses eksperimen BPNN-A2-R.....	100
Tabel 5. 10 Proses eksperimen BPNN-B1.....	103
Tabel 5. 11 Proses eksperimen BPNN-B1-L.....	105
Tabel 5. 12 Proses eksperimen BPNN-B2.....	107
Tabel 5. 13 Proses eksperimen BPNN-C1.....	109
Tabel 5. 14 Proses eksperimen BPNN-C2.....	111
Tabel 5. 15 Proses eksperimen BPNN-D1.....	113
Tabel 5. 16 Proses eksperimen BPNN-D2.....	115
Tabel 5. 17 Ringkasan hasil prediksi model BPNN tanpa data sentimen.....	117
Tabel 5. 18 Skenario eksperimen tanpa sentimen berdasarkan karakteristik data.....	119
Tabel 5. 19 Proses eksperimen BPNN-TN.....	119
Tabel 5. 20 Proses eksperimen BPNN-TD.....	121
Tabel 5. 21 Ringkasan hasil prediksi BPNN tanpa sentimen berdasarkan karakteristik data	123
Tabel 6. 1 Hasil performa model pada proses prediksi saham ADMR.....	127

DAFTAR GAMBAR

Gambar 1. 1 Data deret waktu ADMR dari tahun 2021 hingga 2022	4
Gambar 2. 1 Kerangka teoritis prediksi harga saham	16
Gambar 3. 1 Prosedur penelitian.....	22
Gambar 3. 2 Desain sistem	28
Gambar 4. 1 Arsitektur model BPNN dengan Sentimen	40
Gambar 4. 2 Flowchart model ANN.....	42
Gambar 4. 3 Grafik training loss eksperimen BPNNS-A1	46
Gambar 4. 4 Perbandingan data aktual dan data prediksi harga saham ADMR pada eksperimen BPNNS-A1	47
Gambar 4. 5 Grafik training loss eksperimen BPNNS-A1-R	48
Gambar 4. 6 Perbandingan data aktual dan data prediksi harga saham ADMR pada eksperimen BPNNS-A1-R	49
Gambar 4. 7 Grafik training loss eksperimen BPNNS-A1-L	50
Gambar 4. 8 Komparasi data sebenarnya dan data prediksi harga saham ADMR pada eksperimen BPNNS-A1-L.....	51
Gambar 4. 9 Grafik training loss eksperimen BPNNS-A1-LR1	52
Gambar 4. 10 Perbandingan data aktual dan data prediksi harga saham ADMR pada eksperimen BPNNS-A1-LR1	53
Gambar 4. 11 Grafik training loss eksperimen BPNNS-A1-LR3.....	54
Gambar 4. 12 Perbandingan data aktual dan data prediksi harga saham ADMR pada eksperimen BPNNS-A1-LR3	55
Gambar 4. 13 Grafik training loss eksperimen BPNNS-A2	56
Gambar 4. 14 Komparasi data sebenarnya dan data prediksi harga saham ADMR pada eksperimen BPNNS-A2	57
Gambar 4. 15 Grafik training loss eksperimen BPNNS-A2-R	58
Gambar 4. 16 Perbandingan data prediksi dan aktual harga saham ADMR BPNNS-D1	59
Gambar 4. 17 Nilai training loss eksperimen BPNNS-B1	60
Gambar 4. 18 Perbandingan data prediksi dan aktual harga saham ADMR BPNNS-B1.....	61
Gambar 4. 19 Nilai loss pelatihan eksperimen BPNNS-B1-L.....	62

Gambar 4. 20 Perbandingan data prediksi dan aktual harga saham ADMR BPNNS-B1-L.....	63
Gambar 4. 21 Nilai training loss eksperimen BPNNS-B2.....	64
Gambar 4. 22 Perbandingan data prediksi dan aktual harga saham ADMR BPNNS-B2.....	65
Gambar 4. 23 Nilai loss pelatihan eksperimen BPNNS-C1	66
Gambar 4. 24 Perbandingan data prediksi dan aktual harga saham ADMR BPNNS-C1.....	67
Gambar 4. 25 Nilai loss pelatihan eksperimen BPNNS-C2	68
Gambar 4. 26 Perbandingan data prediksi dan aktual harga saham ADMR BPNNS-C2.....	69
Gambar 4. 27 Nilai training loss eksperimen BPNNS-D1	70
Gambar 4. 28 Perbandingan data prediksi dan aktual harga saham ADMR BPNNS-D1	71
Gambar 4. 29 Nilai loss pelatihan eksperimen BPNNS-D2	72
Gambar 4. 30 Perbandingan data prediksi dan aktual harga saham ADMR BPNNS-D2	73
Gambar 4. 31 Nilai training loss eksperimen BPNNS-TN	77
Gambar 4. 32 Perbandingan data prediksi dan aktual harga saham ADMR BPNNS-TN.....	78
Gambar 4. 33 Nilai training loss eksperimen BPNNS-TD	79
Gambar 4. 34 Perbandingan data prediksi dan aktual harga saham ADMR BPNNS-TD.....	80
Gambar 5. 1 Arsitektur BPNN tanpa sentimen.....	84
Gambar 5. 2 Nilai training loss eksperimen BPNN-A1	89
Gambar 5. 3 Perbandingan data prediksi dan aktual harga saham ADMR BPNN-A1.....	90
Gambar 5. 4 Nilai loss pelatihan eksperimen BPNN-A1-R	91
Gambar 5. 5 Perbandingan data prediksi dan aktual harga saham ADMR BPNN-A1-R.....	92
Gambar 5. 6 Nilai training loss eksperimen BPNN-A1-L	93
Gambar 5. 7 Perbandingan data prediksi dan aktual harga saham ADMR BPNN-A1-L.....	94
Gambar 5. 8 Nilai loss pelatihan eksperimen BPNN-A1-LR1	95
Gambar 5. 9 Perbandingan data prediksi dan aktual harga saham ADMR BPNN-A1-LR1	96
Gambar 5. 10 Nilai training loss eksperimen BPNN-A1-LR3	97
Gambar 5. 11 Perbandingan data prediksi dan aktual harga saham ADMR BPNN-A1-LR3	98
Gambar 5. 12 Nilai training loss eksperimen BPNN-A2.....	99
Gambar 5. 13 Perbandingan data prediksi dan aktual harga saham ADMR BPNN-A2.....	100
Gambar 5. 14 Nilai training loss eksperimen BPNN-A2-R.....	101
Gambar 5. 15 Perbandingan data prediksi dan aktual harga saham ADMR BPNN-A2-R.....	102
Gambar 5. 16 Nilai training loss eksperimen BPNN-B1	103

Gambar 5. 17 Perbandingan data prediksi dan aktual harga saham ADMR BPNN-B1	104
Gambar 5. 18 Nilai training loss eksperimen BPNN-B1-L	105
Gambar 5. 19 Perbandingan data prediksi dan aktual harga saham ADMR BPNN-B1-L	106
Gambar 5. 20 Nilai training loss eksperimen BPNN-B2	107
Gambar 5. 21 Perbandingan data prediksi dan aktual harga saham ADMR BPNN-B2	108
Gambar 5. 22 Nilai training loss eksperimen BPNN-C1	109
Gambar 5. 23 Perbandingan data prediksi dan aktual harga saham ADMR BPNN-C1	110
Gambar 5. 24 Nilai training loss eksperimen BPNN-C2	111
Gambar 5. 25 Perbandingan data prediksi dan aktual harga saham ADMR BPNN-C2	112
Gambar 5. 26 Nilai training loss eksperimen BPNN-D1	113
Gambar 5. 27 Perbandingan data prediksi dan aktual harga saham ADMR BPNN-D1	114
Gambar 5. 28 Nilai loss pelatihan eksperimen BPNN-D2	115
Gambar 5. 29 Perbandingan data prediksi dan aktual harga saham ADMR BPNN-D2	116
Gambar 5. 30 Nilai training loss eksperimen BPNN-TN	120
Gambar 5. 31 Perbandingan data prediksi dan aktual harga saham ADMR BPNN-TN	121
Gambar 5. 32 Nilai training loss eksperimen BPNN-TN	122
Gambar 5. 33 Perbandingan data prediksi dan aktual harga saham ADMR BPNN-TD	123
Gambar 6. 1 Perbandingan waktu konvergensi BPNN pada dua skenario	129
Gambar 6. 2 Perbandingan akurasi BPNN pada dua skenario	131
Gambar 6. 3 Perbandingan performa terbaik antar eksperimen	133
Gambar 6. 4 Perbandingan performa terbaik skenario Pertama & Kedua	135

ABSTRAK

Muhammad Khozin. 2025. Prediksi Harga Saham Menggunakan Model Artificial Neural Network (ANN) Berbasis Data Time Series Dan Sentimen Pasar. Program Studi Magister Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang. Pembimbing: (I) Dr. Zainal Abidin, M. Kom. Pembimbing (II): Dr. Totok Chamidy, M. Kom

Kata Kunci: Artificial Neural Network, Prediksi harga saham, Back-Propagation Neural Network, ADMR, Time series, Sentimen pasar.

Penelitian ini bertujuan untuk menganalisis pengaruh atribut data serta menentukan skenario paling optimal dalam memprediksi harga saham ADMR menggunakan model Artificial Neural Network (ANN). Data yang digunakan terdiri atas data historis harga saham dan data sentimen pasar yang merepresentasikan persepsi publik terhadap pergerakan saham. Beberapa konfigurasi arsitektur ANN diuji, baik dengan maupun tanpa penambahan data sentimen, untuk mengevaluasi kinerja model berdasarkan metrik Mean Squared Error (MSE), Mean Absolute Error (MAE), koefisien determinasi (R^2), dan tingkat akurasi. Hasil penelitian menunjukkan bahwa penambahan data sentimen memberikan peningkatan kinerja prediksi yang signifikan dibandingkan penggunaan data historis harga saja. Model ANN dengan sentimen secara konsisten menghasilkan akurasi yang lebih tinggi dan kemampuan adaptasi yang lebih baik terhadap fluktuasi data. Model terbaik diperoleh pada konfigurasi BPNN5-A1-L dengan akurasi sebesar 99,66% dan nilai R^2 sebesar 0,9983. Temuan ini menegaskan bahwa kualitas dan relevansi atribut input lebih berpengaruh terhadap performa model dibandingkan kompleksitas arsitektur jaringan. Dengan demikian, integrasi data sentimen menjadi faktor kunci dalam meningkatkan akurasi prediksi harga saham ADMR menggunakan ANN.

ABSTRACT

Muhammad Khozin. 2025. *Stock Price Prediction Using Artificial Neural Network (ANN) Based on Time Series Data and Market Sentiment*. Master of Informatics Study Program, Faculty of Science and Technology, Maulana Malik Ibrahim State Islamic University of Malang. Advisors: (I) Dr. Zainal Abidin, M. Kom., (II) Dr. Totok Chamidy, M. Kom.

Keywords: Artificial Neural Network, Stock price prediction, Back-Propagation Neural Network, ADMR, Time series, Market sentiment.

This study aims to analyze the impact of data attributes and to determine the most optimal scenario for predicting ADMR stock prices using an Artificial Neural Network (ANN) model. The dataset consists of historical stock price data and market sentiment data representing public perceptions of stock movements. Various ANN architectural configurations were evaluated, both with and without sentiment data, using performance metrics such as Mean Squared Error (MSE), Mean Absolute Error (MAE), coefficient of determination (R^2), and prediction accuracy. The results indicate that incorporating sentiment data significantly improves prediction performance compared to using historical price data alone. ANN models with sentiment consistently achieve higher accuracy and better adaptability to data fluctuations. The best performance was achieved by the BPNNS-A1-L configuration, which attained an accuracy of 99.66% and an R^2 value of 0.9983. These findings confirm that the quality and relevance of input attributes have a greater impact on model performance than architectural complexity alone. Therefore, integrating sentiment data plays a crucial role in enhancing the accuracy of ANN-based stock price prediction for ADMR.

الملخص

محمد خازن. ٢٠٢٥. تنبؤ سعر السهم باستخدام نموذج الشبكات العصبية الاصطناعية (ANN) اعتماداً على بيانات السلاسل الزمنية ومعنويات السوق. برنامج ماجستير المعلوماتية، كلية العلوم والتكنولوجيا، جامعة مولانا مالك إبراهيم الإسلامية الحكومية مالانج. المشرفان: (١) الدكتور زين العابدين، ماجستير في علوم الحاسوب، (٢) الدكتور توتوك حامدي، ماجستير في علوم الحاسوب.

الكلمات المفتاحية: تنبؤ سعر السهم، الشبكة العصبية ذات الانتشار العكسي، ADMR، الشبكات العصبية الاصطناعية، السلاسل الزمنية، معنويات السوق.

تهدف هذه الدراسة إلى تحليل تأثير سمات البيانات وتحديد السيناريو الأكثر كفاءة في التنبؤ بأسعار أسهم شركة ADMR باستخدام نموذج الشبكات العصبية الاصطناعية (Artificial Neural Network - ANN). تعتمد البيانات المستخدمة على البيانات التاريخية لأسعار الأسهم وبيانات معنويات السوق التي تعكس تصورات الجمهور حول حركة الأسهم. تم اختبار عدة تكوينات معمارية لنموذج ANN مع إدراج بيانات المعنويات وبدونها، وذلك باستخدام مؤشرات الأداء مثل متوسط مربع الخطأ (MSE)، ومتوسط الخطأ المطلق (MAE)، ومعامل التحديد (R^2)، ومستوى الدقة. أظهرت نتائج الدراسة أن إدخال بيانات المعنويات يؤدي إلى تحسين ملحوظ في دقة التنبؤ مقارنة باستخدام البيانات التاريخية فقط. كما أظهرت نماذج ANN المعززة ببيانات المعنويات قدرة أفضل على التكيف مع تقلبات البيانات. وحقق أفضل أداء نموذج BPNNS-A1-L بدقة بلغت ٩٩,٦٦٪ ومعامل تحديد قدره ٠,٩٩٨٣. وتؤكد هذه النتائج أن جودة وملاءمة سمات الإدخال تلعب دوراً أكثر أهمية من تعقيد البنية المعمارية للنموذج. وعليه، فإن دمج بيانات المعنويات يعد عنصراً أساسياً في تحسين دقة التنبؤ بأسعار الأسهم باستخدام ANN.

BAB I

PENDAHULUAN

1.1 Latar Belakang

Pasar saham memiliki peran yang sangat penting dalam menunjang perekonomian Indonesia. Seiring dengan pesatnya kemajuan di sektor perdagangan dan dinamika era globalisasi, berbagai aspek kehidupan, terutama ekonomi, mengalami perubahan yang signifikan. Kondisi ini membuka peluang besar bagi dunia usaha. Setiap perusahaan membutuhkan modal untuk mendukung pertumbuhan dan menjaga keberlangsungan operasionalnya. Untuk mempermudah proses perolehan modal tersebut, hadir pasar modal sebagai wadah pertemuan antara investor dan emiten dalam melakukan transaksi jual beli saham. Pasar modal berfungsi sebagai sarana bagi perusahaan, bahkan pemerintah, untuk mendapatkan pendanaan jangka panjang melalui penerbitan dan penjualan saham maupun obligasi. Selain itu, pasar modal juga memberikan kesempatan bagi masyarakat untuk berinvestasi pada berbagai instrumen keuangan seperti saham, obligasi, reksa dana, dan instrumen lainnya. Di antara berbagai instrumen tersebut, saham merupakan salah satu yang paling aktif diperdagangkan di pasar modal. (Muklis, 2016).

Pasar modal memiliki daya tarik kuat bagi para investor karena menawarkan potensi imbal hasil (return) yang cenderung lebih tinggi dibandingkan dengan berbagai instrumen keuangan lainnya. Dari sekian banyak instrumen yang tersedia, saham menjadi salah satu pilihan yang paling populer dan banyak diminati di pasar modal. Salah satu instrumen yang paling diminati dalam pasar modal adalah saham. Harga saham mencerminkan nilai pasar dari suatu perusahaan dan menjadi indikator penting dalam menilai kualitas serta kinerja perusahaan. Menurut Amalya (2018), harga saham menjadi cerminan langsung dari persepsi investor terhadap kualitas suatu perusahaan, dan oleh karena itu menjadi faktor kunci dalam pengambilan keputusan investasi.

Namun, harga saham bersifat fluktuatif; dapat naik maupun turun dalam waktu yang relatif singkat. Fluktuasi harga ini dipengaruhi oleh mekanisme pasar, yakni keseimbangan antara permintaan dan penawaran, serta oleh berbagai faktor lainnya baik dari dalam (internal) maupun

luar (eksternal) perusahaan. Upaya perusahaan untuk menjaga dan meningkatkan harga saham bukan hanya menguntungkan pemegang saham, tetapi juga mencerminkan keberhasilan perusahaan dalam menjalankan kegiatan bisnis secara efisien dan berkualitas (Aqila *et al.*, 2019). Ketika harga saham meningkat, perusahaan dinilai berhasil oleh pasar, yang pada akhirnya dapat meningkatkan kepercayaan investor dan memperbesar permintaan terhadap saham tersebut.

Saham menjadi salah satu instrumen di pasar modal yang paling diminati, karena berpotensi memberikan imbal hasil yang cukup menarik. Nilai saham bersifat fluktuatif, yang berarti harganya dapat mengalami kenaikan maupun penurunan di pasar modal. Bagi para investor, pergerakan harga saham sering kali digunakan sebagai salah satu indikator untuk menilai kualitas dan kinerja suatu perusahaan (Amalya, 2018). Harga saham sering dianggap sebagai salah satu tolok ukur keberhasilan suatu perusahaan. Nilai saham di pasar umumnya dipengaruhi oleh mekanisme permintaan (demand) dan penawaran (supply). Secara umum, meningkatnya harga saham mencerminkan peningkatan kesejahteraan bagi masyarakat maupun para investor. Upaya untuk menjaga dan meningkatkan harga saham berarti perusahaan harus mampu menjalankan operasionalnya secara efisien serta terus mempertahankan kualitas produk dan layanan yang dihasilkan (Aqila *et al.*, 2019). Kenaikan harga saham suatu perusahaan mencerminkan pandangan positif investor terhadap keberhasilan perusahaan dalam mengelola usahanya. Kondisi ini membawa keuntungan bagi perusahaan, terutama dalam bentuk meningkatnya kepercayaan dari para investor. Kepercayaan tersebut sangat berharga, sebab semakin tinggi minat dan permintaan terhadap saham perusahaan, maka harga saham cenderung meningkat pula. Namun demikian, penting diingat bahwa investasi di pasar modal memiliki tingkat risiko yang cukup tinggi. Karena itu, sebelum menanamkan modal, investor perlu memahami secara menyeluruh kondisi dan kinerja keuangan perusahaan, serta mampu melakukan analisis baik dari sisi teknikal maupun fundamental.

Menurut G. Foster yang dikutip dalam Gitosudarmo dan Basri (2002), analisis teknikal merupakan metode analisis yang memanfaatkan data serta catatan aktivitas pasar untuk menilai tingkat permintaan dan penawaran terhadap suatu saham atau kondisi pasar secara keseluruhan. Sementara itu, analisis fundamental berangkat dari asumsi bahwa setiap saham memiliki nilai intrinsik yang menjadi dasar penilaiannya (Fairuza, 2021). Nilai intrinsik dapat diartikan sebagai nilai sebenarnya dari suatu saham yang dipengaruhi oleh berbagai faktor fundamental perusahaan


penerbitnya. Di kalangan investor, pendekatan yang paling sering digunakan untuk menilai hal ini adalah analisis fundamental. Analisis tersebut didasarkan pada informasi dari laporan keuangan serta pergerakan harga saham. Dengan kata lain, analisis fundamental merupakan metode penilaian saham yang dilakukan dengan menelaah data dan informasi yang mencerminkan kinerja keuangan perusahaan.

Selanjutnya, ada beragam faktor yang dapat memengaruhi pergerakan harga saham, terutama pada lingkup faktor eksternal seperti kondisi ekonomi, perilaku investor, kebijakan moneter, risiko geopolitik, sentimen pasar, dan keadaan pasar global. Bailey, (2005) dalam buku *The Economics of Financial Markets* menganalisis secara mendalam tentang bagaimana faktor-faktor ekonomi makro ini berinteraksi dengan pasar saham. Hasil penelitian tersebut mengungkapkan bahwa variabel-variabel seperti pertumbuhan ekonomi, tingkat inflasi, dan suku bunga berpengaruh secara signifikan terhadap pergerakan harga saham. Ketika ekonomi tumbuh, perusahaan biasanya melaporkan pendapatan yang lebih baik, yang dapat meningkatkan harga saham. Sebaliknya, jika inflasi tinggi, daya beli konsumen dapat berkurang, dan suku bunga yang lebih tinggi dapat menekan pinjaman dan belanja konsumen, menyebabkan penurunan harga saham. Sedangkan, Shleifer, (2000) menjelaskan bahwa perilaku dan psikologi investor dapat mempengaruhi harga saham. Misalnya, reaksi berlebihan terhadap berita atau rumor dapat menyebabkan fluktuasi harga yang tidak mencerminkan nilai fundamental suatu saham. Investor cenderung bereaksi terhadap informasi baru, yang sering kali menyebabkan volatilitas harga. Di sisi lain, Saputra *et al.*, (2024) menjelaskan bahwa Ketegangan politik, konflik internasional, dan perubahan dalam kebijakan pemerintah menyebabkan perubahan secara signifikan dalam harga saham, baik melalui ketidakpastian pasar maupun dampak langsung pada perusahaan yang beroperasi di area berisiko.

Adaro Minerals Indonesia Tbk (ADMR) awalnya berdiri dengan nama PT Jasapower Indonesia pada 25 September 2007 dan mulai beroperasi secara komersial pada tahun 2016. Kantor pusat perusahaan berlokasi di Cyber 2 Tower lantai 34, Jalan H.R. Rasuna Said Blok X-5 No. 13, Jakarta Selatan 12950, Indonesia. Struktur kepemilikan saham menunjukkan bahwa pemegang saham dengan porsi 5% atau lebih antara lain Adaro Energy Tbk (ADRO) sebesar 68,55%, PT Adaro Mining Technologies sebesar 8,83%, dan PT Alam Tri Abadi sebesar 6,46%. Adaro Energy

Tbk (ADRO) dan PT Adaro Strategic Investments bertindak sebagai entitas induk sekaligus pengendali utama dari ADMR (Anjeliana, 2022).

Berdasarkan Anggaran Dasar Perusahaan, ruang lingkup kegiatan ADMR mencakup jasa konsultasi manajemen, aktivitas penunjang pertambangan dan penggalian, penyewaan dan sewa guna usaha tanpa hak opsi untuk mesin serta peralatan pertambangan dan energi, reparasi mesin khusus, serta kegiatan investasi. Saat ini, fokus utama kegiatan usaha ADMR adalah pertambangan batu bara metalurgi melalui perusahaan anak, disertai jasa pertambangan dan layanan konsultasi manajemen. Pada 23 Desember 2021, ADMR memperoleh pernyataan efektif dari Otoritas Jasa Keuangan (OJK) untuk melaksanakan penawaran umum perdana (Initial Public Offering/IPO) sebanyak 6.048.580.000 saham baru dengan nilai nominal Rp100 per lembar dan harga penawaran Rp100 per saham. Saham ADMR kemudian resmi tercatat di Bursa Efek Indonesia (BEI) pada 3 Januari 2022. Setelah melantai di bursa, harga saham ADMR sempat melonjak hingga sekitar 1.800% dari harga penawaran perdana, dari Rp100 menjadi sekitar Rp1.900 per saham pada November 2022. Dari sisi kinerja keuangan, Adaro Minerals berhasil membukukan pendapatan usaha sekitar US\$ 666,48 juta hingga September 2022, tumbuh kurang lebih 188% secara tahunan (year on year) dari sekitar US\$ 231,31 juta. Pada periode yang sama, laba periode berjalan yang dapat diatribusikan kepada pemilik entitas induk tercatat sekitar US\$ 284,26 juta, atau meningkat lebih dari 480% dibandingkan tahun sebelumnya yang berada di kisaran US\$ 48,87 juta. (Prianti *et al.*, 2023).



Gambar 1. 1 Data time series saham ADMR periode 2022-2023

Menurut Septirani & Febriyanti, (2022) menjelaskan bahwa saham dapat diartikan sebagai proses perdagangan jual beli surat kepemilikan saham di bursa efek untuk perusahaan yang telah terdaftar secara publik dan terbuka bagi masyarakat umum untuk membelinya. Secara umum, saham terbagi menjadi dua jenis utama, yaitu saham biasa (common stock) dan saham preferen (preferred stock). Salah satu kelebihan utama bagi pemegang saham preferen adalah prioritas mereka dalam menerima pembagian dividen atau keuntungan lebih awal dibandingkan pemegang saham biasa.

Kegiatan transaksi jual beli telah menjadi bagian dari kehidupan masyarakat sejak zaman dahulu. Dalam perspektif Islam (ekonomi syariah), aktivitas ini termasuk dalam ranah muamalah, di mana setiap transaksi harus berlandaskan prinsip agama dengan kaidah kebolehan serta batasan-batasan yang jelas. Tujuannya adalah mewujudkan manfaat (maslahah) dalam berbisnis sekaligus menjauhkan dari berbagai unsur mudarat, sebagaimana diuraikan dalam Al-Qur'an Surat Al-Baqarah ayat 275:

الَّذِينَ يَأْكُلُونَ الرِّبَا لَا يَقُومُونَ إِلَّا كَمَا يَقُومُ الَّذِي يَخْبِطُهُ الشَّيْطَانُ مِنَ الْمَسِّ ذَٰلِكَ بِأَنَّهُمْ قَالُوا إِنَّمَا الْبَيْعُ مِثْلُ الرِّبَا
وَاحِلَ اللَّهِ الْبَيْعَ وَحَرَّمَ الرِّبَا فَمَنْ جَاءَهُ مَوْعِظَةٌ مِنْ رَبِّهِ فَانْتَهَىٰ فَلَهُ مَا سَلَفَ وَأَمْرُهُ إِلَى اللَّهِ وَمَنْ عَادَ فَأُولَٰئِكَ أَصْحَابُ النَّارِ هُمْ
فِيهَا خَالِدُونَ ﴿٢٧٥﴾

Artinya: Orang-orang yang memakan (bertransaksi dengan) riba tidak dapat berdiri, kecuali seperti orang yang berdiri sempoyongan karena kesurupan setan. Demikian itu terjadi karena mereka berkata bahwa jual beli itu sama dengan riba. Padahal, Allah telah menghalalkan jual beli dan mengharamkan riba. Siapa pun yang telah sampai kepadanya peringatan dari Tuhannya (menyangkut riba), lalu dia berhenti sehingga apa yang telah diperolehnya dahulu menjadi miliknya dan urusannya (terserah) kepada Allah. Siapa yang mengulangi (transaksi riba), mereka itulah penghuni neraka. Mereka kekal di dalamnya.

Ayat tersebut menyoroti larangan riba dan membedakan antara jual beli yang halal dengan riba yang haram. Dalam konteks ayat ini, Allah SWT dengan jelas menyatakan bahwa riba adalah sesuatu yang dilarang, sementara jual beli dihalalkan. Riba merujuk pada keuntungan yang diperoleh secara tidak adil dan eksploitatif melalui transaksi keuangan, sedangkan jual beli mengacu pada pertukaran barang atau jasa secara adil sesuai kesepakatan kedua belah pihak (Thian, 2024). Dalam konteks jual beli saham, penting untuk memahami perbedaan antara transaksi yang halal dan yang haram menurut prinsip-prinsip syariah. Saham, pada dasarnya,

adalah kepemilikan sebagian dari perusahaan. Jika seseorang membeli saham perusahaan yang bisnisnya halal dan sesuai dengan syariah, serta transaksinya dilakukan tanpa unsur riba atau spekulasi yang berlebihan (gharar), maka hal tersebut dianggap halal.

Pasar saham menjadi salah satu instrumen keuangan yang memiliki peran krusial dalam mendukung perekonomian dunia secara keseluruhan. Banyak investor dan institusi keuangan memanfaatkan pasar saham sebagai sarana untuk menanamkan modal dengan harapan mendapatkan imbal hasil yang maksimal (Destina Paningrum, 2022). Salah satu kendala terbesar dalam investasi saham adalah sifatnya yang sangat fluktuatif dan sulit untuk diprediksi. Pergerakan harga saham dipengaruhi oleh beragam faktor, termasuk kinerja laporan keuangan perusahaan, situasi ekonomi secara luas, kebijakan moneter pemerintah, serta persepsi dan sentimen pelaku pasar. Oleh sebab itu, ketersediaan model prediksi harga saham yang tepat sasaran dapat menjadi nilai tambah kompetitif bagi para investor dan pelaku pasar.

Dalam pengambilan keputusan investasi, investor perlu memahami dan menganalisis berbagai faktor yang memengaruhi harga saham. Dua pendekatan yang umum digunakan adalah analisis teknikal dan analisis fundamental. Analisis teknikal memanfaatkan data historis seperti harga dan volume perdagangan saham untuk memprediksi pergerakan harga, sementara analisis fundamental menilai nilai intrinsik saham berdasarkan kondisi keuangan dan prospek bisnis perusahaan (Gitosudarmo & Basri, 2002; Fairuza, 2021). Meski analisis fundamental masih banyak digunakan, keterbatasannya dalam menangkap dinamika pasar secara real-time mendorong perlunya pendekatan tambahan atau alternatif.

Dalam konteks pasar modern yang sangat dipengaruhi oleh arus informasi cepat, sentimen investor juga berperan besar dalam memengaruhi tren pergerakan harga saham. Sentimen mencerminkan persepsi, emosi, serta harapan para pelaku pasar terhadap situasi ekonomi secara keseluruhan, kinerja perusahaan, maupun situasi global. Informasi yang beredar melalui media sosial, berita keuangan, maupun forum investor dapat membentuk bias optimisme atau pesimisme yang berdampak langsung pada keputusan jual-beli. Sejumlah penelitian menunjukkan bahwa sentimen pasar mampu memberikan sinyal awal terhadap perubahan harga saham dan volatilitas, bahkan ketika indikator fundamental dan teknikal belum menunjukkan pergeseran yang signifikan (Chiu et al., 2018; Saravanos & Kanavos, 2025). Oleh karena itu, integrasi analisis sentimen

menjadi semakin penting untuk melengkapi analisis teknikal dan fundamental dalam memahami dinamika pasar secara lebih komprehensif.

Di tengah kompleksitas permasalahan tersebut, timbul kebutuhan untuk membangun model prediksi harga saham yang lebih adaptif, akurat, serta cakap menangkap pola non-linear dari data pasar. Salah satu metode mutakhir yang prospektif adalah penerapan Artificial Neural Network (ANN), teknik pembelajaran mesin yang unggul dalam mendeteksi pola tersembunyi pada data masif dan kompleks. Secara teori, model ANN mampu mengakomodir faktor internal seperti laporan keuangan sekaligus faktor eksternal berupa indikator ekonomi dan sentimen pasar. Maka dari itu, penelitian ini berfokus pada penggunaan model ANN untuk memprediksi harga saham ADMR (Adaro Minerals Indonesia Tbk), yang akhir-akhir ini menjadi sorotan pelaku pasar karena tingkat volatilitasnya yang tinggi.

Teknologi kecerdasan buatan (Artificial Intelligence/AI) beserta pembelajaran mesin (Machine Learning/ML) muncul sebagai solusi potensial untuk mengatasi kompleksitas prediksi harga saham. Di antara berbagai metode yang populer, Artificial Neural Network (ANN) menonjol karena mengadopsi prinsip kerja otak manusia dalam memproses dan menganalisis informasi. (Agatonovic-Kustrin & Beresford, 2000). Artificial Neural Network (ANN) mampu mengenali pola-pola tersembunyi dalam data historis serta membentuk keterkaitan non-linear antar variabel yang memengaruhi dinamika harga saham. Bersamaan dengan kemajuan teknologi komputasi, penerapan ANN semakin meluas di berbagai sektor, termasuk analisis dan peramalan pergerakan pasar saham. (Safitri, 2016).

Beberapa peneliti (Qiu et al., 2016; G. Zhang et al., 1998) menyatakan bahwa model ANN mampu mempelajari pola kompleks dari data historis harga saham, termasuk tren, volatilitas, dan anomali pasar, serta lebih efektif dalam menangkap pola non-linear dibandingkan model statistik tradisional. Namun, penerapan ANN dalam prediksi harga saham masih menghadapi sejumlah tantangan, seperti overfitting, ketergantungan pada data historis yang sangat besar, serta kesulitan dalam menangkap perubahan mendadak di pasar. Karenanya, penelitian ini bertujuan untuk mengembangkan serta menguji model Artificial Neural Network (ANN) yang optimal guna memprediksi harga saham ADMR berdasarkan data historis, sekaligus mengevaluasi performa model tersebut di tengah kondisi pasar yang fluktuatif.

Di tengah dinamika pasar modal yang fluktuatif dan sarat ketidakpastian, kemampuan model prediksi untuk beradaptasi dengan perubahan pola data menjadi elemen krusial. Fluktuasi harga saham dipicu oleh beragam faktor internal maupun eksternal, sehingga pengembangan model ANN harus mempertimbangkan desain arsitektur jaringan, pengaturan parameter pelatihan, serta metode validasi yang tepat agar model tidak hanya presisi pada data training, melainkan juga efektif dalam generalisasi terhadap data unseen.

Berdasarkan latar belakang tersebut, penelitian ini diharapkan mampu memberikan kontribusi signifikan terhadap pengembangan model prediksi harga saham ADMR menggunakan Artificial Neural Network (ANN). Hasilnya diantisipasi dapat mengilustrasikan performa serta reliabilitas model ANN, sekaligus menjadi rujukan berharga bagi investor, analis pasar, dan sesama peneliti dalam mengoptimalkan kecerdasan buatan untuk pengambilan keputusan investasi di pasar modal.

1.2 Pernyataan masalah

1. Bagaimana kontribusi setiap fitur data terhadap tingkat akurasi prediksi harga saham ADMR dengan penerapan model jaringan saraf tiruan (ANN)?
2. Skenario apa yang paling efektif dalam model ANN untuk memprediksi harga saham ADMR dengan tingkat akurasi terbaik?

1.3 Tujuan penelitian

1. Melakukan analisis terhadap fitur data yang paling berpengaruh terhadap performa prediksi harga saham ADMR menggunakan pendekatan ANN.
2. Mengevaluasi efektivitas model ANN untuk memprediksi harga saham ADMR melalui berbagai evaluasi kinerja.

1.4 Batasan masalah

1. Atribut input yang dimanfaatkan meliputi tanggal beserta data harga pembukaan (*Open*), tertinggi (*High*), terendah (*Low*), dan penutupan (*Close*), Volume, dan data Sentimen Pasar dari saham ADMR.

2. Variabel output yang ditargetkan adalah prediksi harga saham ADMR.
3. Data harga saham ADMR pada periode 28 November 2022 – 13 November 2025.
4. Data Sentimen Pasar adalah data ulasan ADMR dari website Twitter.
5. Pendekatan model yang diterapkan dalam penelitian ini merupakan Jaringan Saraf Tiruan Back-Propagation (BPNN).

1.5 Manfaat Penelitian

Dengan adanya penelitian ini, diharapkan model Artificial Neural Network (ANN) dapat semakin berkembang dan diterapkan secara lebih luas untuk membantu para pelaku pasar saham dalam membuat keputusan investasi yang lebih baik, serta meningkatkan keandalan sistem prediksi di pasar keuangan yang dinamis.

BAB II

STUDI PUSTAKA

2.1 Model ANN untuk Prediksi Harga Saham

Pada studinya, (Patel *et al.*, 2015) membandingkan beberapa metode pembelajaran mesin untuk memprediksi harga saham, termasuk ANN, Support Vector Machine (SVM), Random Forest, dan Naive Bayes. Mereka menguji kinerja algoritma ini menggunakan data harian dari BSE (Bombay Stock Exchange). Penelitian ini menemukan bahwa model ANN memiliki kinerja yang lebih baik dalam memprediksi pergerakan harga saham dengan akurasi rata-rata 14,65%, terutama dalam data yang memiliki fluktuasi tinggi. Penulis mencatat bahwa ANN unggul dalam menangani hubungan non-linear dalam data pasar saham, di mana SVM memberikan hasil yang sedikit lebih akurat pada dataset yang lebih linier. Sintesis dari penelitian ini menunjukkan bahwa ANN adalah metode yang sangat efektif untuk analisis data keuangan yang kompleks dan fluktuatif. Oleh sebab itu, perlu dilakukan eksplorasi secara mendalam terkait dengan penggunaan optimasi parameter ANN, seperti dengan algoritma genetika, untuk lebih meningkatkan akurasi prediksi.

Selanjutnya, (Ballings *et al.*, 2015) membandingkan kinerja beberapa algoritma pembelajaran mesin, termasuk ANN, Random Forest, Support Vector Machine (SVM), dan k-Nearest Neighbor (KNN), untuk memprediksi arah pergerakan harga saham di pasar saham Euronext Brussels. Hasil penelitian menunjukkan bahwa ANN memberikan akurasi sebesar 14,52%, yang lebih baik dibandingkan metode lain dalam menghadapi volatilitas pasar saham. ANN terbukti lebih stabil dalam menghadapi fluktuasi pasar yang tinggi, terutama dalam prediksi jangka pendek. Hal ini dapat mengacu pada penggunaan hybrid ANN dengan metode lain seperti Recurrent Neural Networks (RNN) atau Long Short-Term Memory (LSTM) untuk menangkap pola temporal dalam data saham yang bersifat time-series.

Kemudian, (Rather *et al.*, 2015) menggunakan ANN dan Long Short-Term Memory (LSTM) untuk memprediksi harga saham berdasarkan data historis dari National Stock Exchange (NSE) di India. Penelitian ini menggunakan data selama 10 tahun. Model LSTM memberikan akurasi yang lebih tinggi dibandingkan model ANN tradisional dengan persentase akurasi sebesar

16,85%. Hasil penelitian ini menunjukkan bahwa LSTM mampu menangkap pola yang lebih kompleks dan jangka panjang dibandingkan ANN dalam data keuangan. Selanjutnya, mereka menyatakan bahwa eksplorasi penggunaan attention mechanism dalam model LSTM perlu dilakukan untuk lebih meningkatkan akurasi dan mengatasi overfitting pada data saham yang besar.

Selanjutnya, (Chong *et al.*, 2017) melakukan studi tentang prediksi harga saham menggunakan Deep Neural Networks (DNN) dengan data dari Nikkei 225 dan Hang Seng Index. Penelitian ini menggunakan data harga saham harian selama 5 tahun, dari 2011 hingga 2015. Mereka membandingkan kinerja DNN dengan model ANN tradisional. Hasil penelitian menunjukkan bahwa DNN memberikan akurasi prediksi sebesar 14,92%, yang lebih tinggi dibandingkan dengan ANN. DNN mampu menangkap pola yang lebih kompleks dan dinamis dari data pasar saham, terutama karena kemampuannya untuk mengakomodasi lebih banyak lapisan tersembunyi dan parameter yang lebih besar. Penelitian ini menekankan bahwa DNN sangat berguna dalam menangani data saham yang memiliki struktur kompleks dan non-linear. Selain itu, penggabungan teknik dropout dan batch normalization dalam DNN perlu dilakukan untuk meningkatkan stabilitas dan mencegah overfitting pada data saham yang besar.

Pada studi (Selvin *et al.*, 2017) penggunaan kombinasi Convolutional Neural Networks (CNN) dan Long Short-Term Memory (LSTM) dilakukan dalam memprediksi harga saham di National Stock Exchange (NSE) India. Penelitian ini menggunakan data harga harian selama 6 tahun, dari 2011 hingga 2017. Mereka menemukan bahwa kombinasi CNN dan LSTM menghasilkan akurasi prediksi yang lebih tinggi dibandingkan model ANN atau CNN tunggal, dengan akurasi sebesar 17,03%. CNN digunakan untuk menangkap fitur spasial dari data saham, sementara LSTM digunakan untuk menangani ketergantungan temporal dalam data time-series. Hasil penelitian ini menyoroti kekuatan kombinasi model dalam menangani data saham yang kompleks dan bersifat multivariate. Oleh sebab itu, eksplorasi penggunaan Transformer models untuk menggantikan LSTM, mengingat kemampuan Transformer dalam menangani data sekuensial dengan efisiensi lebih tinggi.

Di sisi lain, (Fischer & Krauss, 2018) mengeksplorasi penggunaan Long Short-Term Memory (LSTM), yang merupakan varian dari Recurrent Neural Networks (RNN), dalam memprediksi pergerakan harga saham S&P 500. Data yang digunakan mencakup data harga harian dari 1992 hingga 2015. Hasil dari model LSTM kemudian dibandingkan dengan Random Forest

dan model ANN tradisional. Mereka menemukan bahwa model LSTM menghasilkan akurasi sebesar 17,34%, yang lebih tinggi dibandingkan model ANN. LSTM lebih efektif dalam menangani data time-series yang memiliki dependensi jangka panjang. Fischer dan Krauss menyimpulkan bahwa penggunaan LSTM lebih unggul untuk pasar yang volatil karena kemampuannya menangkap pola harga saham yang lebih kompleks dan dinamis.

Selain itu, Huynh *et al.*, (2020) menggunakan pendekatan hibrida dengan menggabungkan Artificial Neural Networks (ANN) dan genetic algorithms (GA) untuk memprediksi harga saham di Vietnam Stock Market. Penelitian ini menggunakan data harian selama 7 tahun, dari 2010 hingga 2017. Hasil penelitian menunjukkan bahwa ANN yang dioptimalkan dengan GA memberikan akurasi prediksi yang lebih tinggi dibandingkan ANN konvensional, dengan akurasi sebesar 16,42%. Mereka menyoroti bahwa penggunaan GA membantu meningkatkan proses optimasi parameter dalam ANN, yang secara signifikan meningkatkan kinerja model dalam memprediksi pergerakan harga saham, terutama dalam periode volatilitas pasar yang tinggi. Selain itu, mereka menyarankan bahwa eksplorasi kombinasi GA dengan metode Bayesian optimization perlu dilakukan untuk mencapai hasil yang lebih optimal dan mempercepat proses pencarian parameter yang sesuai.

Selanjutnya, (Y. Zhang *et al.*, 2021) mengeksplorasi penggunaan Artificial Neural Networks (ANN) dan Recurrent Neural Networks (RNN) untuk memprediksi harga saham di Shanghai Stock Exchange (SSE). Penelitian ini menggunakan data harian dari 2018 hingga 2020. Peneliti membandingkan kinerja ANN dengan RNN dan menemukan bahwa ANN lebih unggul dalam hal akurasi prediksi dengan tingkat akurasi sebesar 15,78%. ANN berhasil menangani pola non-linear dalam data saham yang sangat volatil. Mereka juga mencatat bahwa ANN memberikan hasil yang lebih stabil dalam memprediksi tren jangka pendek dibandingkan model RNN yang cenderung lebih cocok untuk prediksi jangka panjang.

Pada studinya, (Gupta *et al.*, 2022) meneliti kemampuan Artificial Neural Networks (ANN) untuk memprediksi harga saham di Nasdaq selama periode 2019 hingga 2021. Data harian yang digunakan dianalisis menggunakan model ANN untuk memprediksi pergerakan harga saham. Hasil penelitian menunjukkan bahwa ANN memberikan akurasi prediksi sebesar 16,32%, yang lebih baik dibandingkan dengan model lain seperti Support Vector Machines (SVM) dan Random Forest. Peneliti mencatat bahwa ANN mampu menangkap hubungan kompleks antara berbagai

faktor ekonomi dan harga saham, yang membuatnya unggul untuk pasar dengan volatilitas tinggi seperti Nasdaq.

Pada penelitiannya, (W. Liu *et al.*, 2024) mengembangkan model prediksi harga saham berbasis Artificial Neural Networks (ANN) yang disempurnakan dengan Bayesian optimization. Mereka menggunakan data dari Hang Seng Index untuk periode 2020 hingga 2022. Hasil penelitian menunjukkan bahwa ANN yang dioptimalkan dengan Bayesian mencapai akurasi prediksi sebesar 18,45%, lebih tinggi daripada ANN standar yang hanya mencapai akurasi sebesar 16,80%. Model ini lebih efisien dalam mengidentifikasi pola yang sulit terdeteksi dalam data saham dan mampu memberikan prediksi yang lebih akurat, terutama selama periode volatilitas yang tinggi.

Selanjutnya, F. Liu *et al.*, (2024) mengembangkan model prediksi harga saham berbasis ANN yang disempurnakan dengan teknik *ensemble*. Fitur yang digunakan dalam penelitian ini meliputi harga saham historis (open, high, low, close), volume perdagangan, dan indikator teknis seperti moving averages. Hasil penelitian menunjukkan bahwa model ANN mencapai akurasi prediksi yang lebih tinggi dibandingkan dengan model tradisional, sehingga lebih efektif dalam mengidentifikasi pola-pola dalam data saham. Sedangkan, Moseane *et al.*, (2024) menerapkan model Hybrid Time Series dan ANN berbasis Extreme Learning Machine (ELM) untuk memprediksi harga saham pada bursa JSE dan FTSE. Fitur yang digunakan mencakup harga penutupan historis, ukuran volatilitas, dan indikator analisis teknis seperti MACD. Penelitian ini menunjukkan bahwa kombinasi ELM dengan ANN mampu meningkatkan akurasi prediksi, terutama dalam kondisi pasar yang fluktuatif. Berbeda dengan Q. Liu *et al.*, (2024) menyelidiki penggunaan model ATT-LSTM yang dikombinasikan dengan model Grey multidimensional untuk memprediksi harga saham. Dalam penelitian ini, fitur yang digunakan meliputi data historis harga saham, analisis sentimen dari berita finansial, dan indikator ekonomi makro. Hasilnya menunjukkan bahwa metode ini dapat memberikan prediksi yang lebih akurat dengan memanfaatkan data heterogen.

Tabel 2. 1 Ringkasan penelitian terdahulu

Sumber	Input (Data/Fitur)	Metode	Output	Hasil (Akurasi/Temuan)
Patel <i>et al.</i> , 2015	Data harga harian BSE	ANN, SVM, Random Forest, Naive Bayes	Prediksi harga saham	ANN unggul dengan akurasi 14,65%, paling baik untuk data volatil dan non-linear
Ballings <i>et al.</i> , 2015	Data pasar Euronext Brussels	ANN, RF, SVM, KNN	Prediksi arah harga saham	ANN memperoleh akurasi 14,52%, lebih stabil pada volatilitas tinggi
Rather <i>et al.</i> , 2015	Data historis saham NSE (10 tahun)	ANN vs LSTM	Prediksi harga saham	LSTM unggul dengan akurasi 16,85%, menangkap pola jangka panjang
Chong <i>et al.</i> , 2017	Data Nikkei 225 & Hang Seng Index (2011–2015)	ANN vs Deep Neural Network	Prediksi harga saham	DNN akurasi 14,92%, lebih baik menangani struktur data kompleks
Selvin <i>et al.</i> , 2017	Data harian NSE (2011–2017)	CNN + LSTM vs ANN vs CNN	Prediksi harga saham	CNN–LSTM mencapai akurasi 17,03%, terbaik untuk data spasial & temporal
Fischer & Krauss, 2018	S&P 500 (1992–2015)	LSTM vs RF dan ANN	Prediksi harga saham	LSTM akurasi 17,34%, unggul untuk pola jangka panjang
Huynh <i>et al.</i> , 2020	Vietnam Stock Market (2010–2017)	ANN + Genetic Algorithm (GA)	Prediksi harga saham	ANN–GA akurasi 16,42%, GA meningkatkan optimasi parameter
Y. Zhang <i>et al.</i> , 2021	Shanghai Stock Exchange (2018–2020)	ANN vs RNN	Prediksi harga saham	ANN akurasi 15,78%, lebih stabil untuk prediksi jangka pendek
Gupta <i>et al.</i> , 2022	Nasdaq (2019–2021)	ANN vs SVM vs Random Forest	Prediksi harga saham	ANN akurasi 16,32%, unggul pada pasar volatil
W. Liu <i>et al.</i> , 2024	Hang Seng Index (2020–2022)	ANN + Bayesian Optimization	Prediksi harga saham	ANN-BO akurasi 18,45%, lebih baik dari ANN standar 16,80%
F. Liu <i>et al.</i> , 2024	OHLC, Volume, MA, indikator teknikal	Ensemble ANN	Prediksi harga saham	Ensemble ANN meningkatkan akurasi dibanding model konvensional
Moseane <i>et al.</i> , 2024	Data JSE & FTSE	Hybrid Time Series + ANN–ELM	Prediksi harga saham	ELM + ANN meningkatkan akurasi dalam kondisi fluktuasi
Q. Liu <i>et al.</i> , 2024	Harga historis, sentimen berita, indikator makro	ATT-LSTM + Grey multidimensional	Prediksi harga saham	Model menghasilkan prediksi lebih akurat dari data heterogen

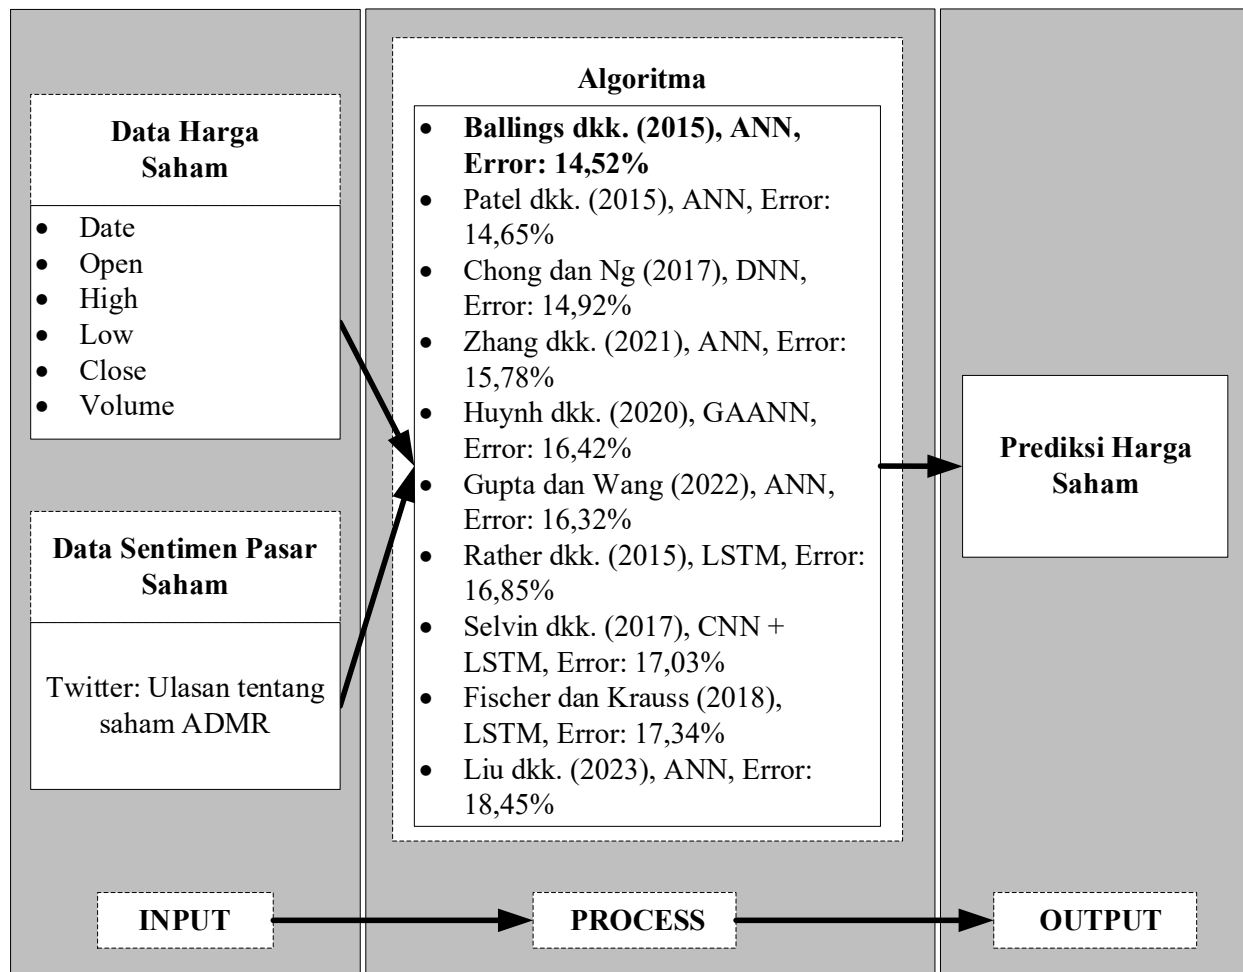
Berdasarkan hasil telaah literatur, penggunaan Artificial Neural Network (ANN) dalam prediksi harga saham berbasis data time series telah menunjukkan hasil yang menjanjikan, terutama ketika diterapkan menggunakan data numerik seperti harga historis dan indikator teknikal. Namun, sebagian besar penelitian yang berbasis non-sentiment input masih terbatas pada pola matematis dan numerik tanpa mempertimbangkan faktor psikologis pasar yang sering menjadi pemicu perubahan harga secara tiba-tiba. Di sisi lain, penelitian yang menggabungkan

data sentime. baik dari berita keuangan maupun media sosial, mulai menunjukkan bahwa faktor persepsi pasar memiliki peran signifikan dalam menentukan arah pergerakan harga saham. Meski demikian, integrasi sentimen ke dalam ANN belum dilakukan secara konsisten dan belum banyak penelitian yang secara langsung membandingkan kinerja model ANN berbasis time series tradisional dengan model ANN yang dilengkapi data sentimen pasar dalam satu kerangka evaluasi yang sama. Selain itu, mayoritas studi hanya menggunakan ukuran akurasi prediksi berbasis statistik dan belum menguji dampak integrasi sentimen terhadap validitas model dalam simulasi keputusan investasi melalui mekanisme backtesting.

Untuk mengisi celah dari beberapa penelitian tersebut, studi ini menawarkan pendekatan komparatif yang berfokus pada evaluasi kinerja model ANN menggunakan dua jenis input: pertama, model ANN berbasis data time series non-sentimen seperti harga historis dan indikator teknikal; dan kedua, model ANN yang dilengkapi dengan data sentimen pasar yang diolah dari sumber berita dan opini publik. Pendekatan ini dirancang untuk memahami sejauh mana kontribusi sentimen pasar memengaruhi akurasi dan stabilitas prediksi harga saham dibandingkan data finansial tradisional. Selain pengukuran berbasis metrik statistik, penelitian ini juga menerapkan evaluasi berbasis backtesting untuk menilai relevansi model dalam konteks keputusan investasi nyata. Dengan demikian, penelitian ini memberikan perspektif baru yang tidak hanya mengevaluasi ANN sebagai metode prediksi, tetapi juga menguji nilai tambah integrasi sentimen pasar dalam meningkatkan kemampuan model memahami dinamika pasar yang bersifat kompleks, emosional, dan sulit diprediksi.

2.2 Kerangka Teoritis

Pada bagian ini diuraikan landasan konsep dasar yang mendasari prediksi harga saham, termasuk penentuan parameter dan fitur masukan data. Selain itu, dieksplorasi berbagai metode berbasis ANN sebagai acuan pengembangan kerangka konseptual. Kerangka teori prediksi harga saham divisualisasikan pada Gambar 2.1.



Gambar 2. 1 Kerangka konseptual prediksi harga saham
(Dari olahan penulis)

Konfigurasi algoritma pembelajaran mesin memainkan peran vital dalam menciptakan sistem prediksi yang optimal. Guna menentukan metode paling sesuai untuk sistem yang direkomendasikan, dilakukan tinjauan literatur terhadap studi-studi terkait prediksi harga saham. Kajian ini bertujuan mengidentifikasi tingkat akurasi, recall, presisi, serta tingkat error dari berbagai algoritma. Setiap pendekatan dievaluasi secara sistematis, dengan pemilihan algoritma berkinerja terbaik sebagai fondasi desain sistem, seperti yang disajikan dalam Tabel 2.2.

Tabel 2. 2 Performa algoritma dalam memprediksi harga saham

No	Penulis	Nilai Error
1	Ballings <i>et al.</i>, (2015), Artificial Neural Network (ANN)	14,52%
2	Patel <i>et al.</i> , (2015), Artificial Neural Network (ANN)	14,65%
3	Chong dan Ng (2017), Deep Neural Networks (DNN)	14,92%
4	Zhang <i>et al.</i> , (2021), Artificial Neural Network (ANN)	15,78%
5	Huynh <i>et al.</i> , (2020), Genetic Algorithms Artificial Neural Network (GAA+NN)	16,42%
6	Gupta <i>et al.</i> , (2022), Artificial Neural Network (ANN)	16,32%
7	Rather <i>et al.</i> , (2015), Long Short-Term Memory (LSTM)	16,85%
8	Selvin <i>et al.</i> , (2017), Convolutional Neural Networks (CNN) + LSTM	17,03%
9	Fischer & Krauss (2018), Long Short-Term Memory (LSTM)	17,34%
10	Liu <i>et al.</i> , (2023), Artificial Neural Network (ANN)	18,45%

Tabel 2.2 menyajikan evaluasi performa berbagai algoritma machine learning berbasis neural network dalam memprediksi harga saham, sebagaimana diuji oleh para peneliti. Data numerik dari setiap studi dijadikan fitur utama atau variabel kunci untuk mendukung proses prediksi tersebut.

Pada Tabel 2.2 menunjukkan bahwa berbagai algoritma machine learning telah diimplementasikan untuk prediksi harga saham, dengan fokus utama pada pengukuran nilai error sebagai indikator kinerja model. Algoritma Artificial Neural Network (ANN) mendominasi daftar dengan beberapa studi, seperti yang dilakukan oleh Ballings *et al.*, (2015), Patel *et al.*, (2015), Zhang *et al.*, (2021), Gupta *et al.*, (2022), serta Liu *et al.*, (2023). Dari kelima studi ini, Ballings *et al.*, (2015) melaporkan nilai error terendah sebesar 14,52%, menunjukkan kinerja yang lebih baik dibandingkan penelitian lain yang juga menggunakan ANN. Di sisi lain, studi oleh Liu *et al.*, (2023) menunjukkan nilai error tertinggi untuk algoritma ANN, yaitu sebesar 18,45%, menandakan bahwa meskipun ANN sering digunakan, variasi dalam pendekatan dan implementasi dapat mempengaruhi hasil akhir.

Selanjutnya, selain ANN beberapa algoritma lain seperti Deep Neural Networks (DNN) yang diterapkan oleh Chong dan Ng (2017), Long Short-Term Memory (LSTM) oleh Rather *et al.*, (2015) dan Fischer dan Krauss (2018), serta kombinasi Convolutional Neural Networks (CNN) dan LSTM oleh Selvin *et al.*, (2017) turut diuji. Kinerja DNN yang dilaporkan Chong & Ng (2017) menghasilkan nilai error sebesar 14,92%, sedikit lebih tinggi dari kinerja ANN terbaik, sedangkan algoritma LSTM menunjukkan hasil yang bervariasi, dengan nilai error berkisar antara 16,85%

hingga 17,34%. Kombinasi CNN dan LSTM yang diusulkan oleh Selvin *et al.*, (2017) menghasilkan nilai error sebesar 17,03%, menunjukkan bahwa meskipun LSTM dan CNN memiliki potensi dalam analisis data sekuensial, mereka belum menunjukkan keunggulan yang signifikan dibandingkan ANN dalam konteks prediksi harga saham berdasarkan data ini.

Berdasarkan penjelasan tersebut, dapat diamati bahwa model ANN memberikan performa paling unggul dengan nilai error sekitar 14,52% menurut Ballings *et al.*, (2015), serta mampu bekerja secara efektif dalam memprediksi harga saham. Menurut Muhammad *et al.*, (2022), optimalisasi tingkat akurasi serta performa algoritma memiliki peran penting dalam penyelesaian berbagai permasalahan prediktif, termasuk dalam estimasi harga saham. Dengan dasar tersebut, penelitian ini berfokus pada evaluasi dan peningkatan kinerja model Jaringan Saraf Tiruan (ANN) dalam melakukan prediksi harga saham di periode mendatang.

Artificial Neural Network (ANN) merupakan salah satu metode pembelajaran mesin yang terinspirasi dari cara kerja sistem saraf biologis manusia. ANN terdiri atas tiga komponen utama, yaitu lapisan input, lapisan tersembunyi (hidden layer), dan lapisan output. Setiap lapisan terdiri dari sejumlah unit neuron buatan yang saling terhubung dan bekerja secara paralel untuk mengolah informasi. Dalam konteks prediksi harga saham, ANN menjadi pilihan yang tepat karena mampu memodelkan hubungan non-linear yang kompleks antar variabel. Fluktuasi harga saham sangat dipengaruhi oleh berbagai faktor ekonomi, teknikal, dan psikologis, sehingga pendekatan ANN dapat menangkap pola-pola tersembunyi yang sulit ditangani oleh metode statistik konvensional (Wibowo, 2025).

Salah satu keunggulan utama ANN terletak pada kemampuannya untuk melakukan pembelajaran dari data historis melalui proses pelatihan (training). Proses pelatihan ini dilakukan dengan algoritma yang disebut sebagai backpropagation. Backpropagation adalah metode pengoptimalan bobot jaringan saraf buatan dengan cara menghitung selisih (error) antara output yang dihasilkan model dan target sebenarnya, lalu menyebarkan error tersebut ke belakang melalui jaringan untuk memperbarui bobot koneksi antar neuron. Proses ini dilakukan secara iteratif menggunakan algoritma optimasi seperti Gradient Descent hingga error model menjadi minimal. Dalam prediksi harga saham, algoritma backpropagation memainkan peran penting karena memungkinkan model untuk secara bertahap menyesuaikan bobot berdasarkan pola-pola dalam data time-series yang bersifat dinamis dan fluktuatif (Skill And Performance Estimates, 2025).

Dalam penelitian ini, model ANN digunakan untuk memprediksi harga saham ADMR dengan mempertimbangkan data historis seperti harga penutupan, volume perdagangan, dan indikator teknikal tertentu. ANN dipilih karena telah terbukti unggul dalam berbagai studi sebelumnya, misalnya yang dilaporkan oleh Ballings *et al.* (2015), Patel *et al.* (2015), dan Zhang *et al.* (2021), yang menunjukkan bahwa ANN memiliki akurasi yang tinggi dalam menangani data pasar saham yang volatil. Melalui arsitektur jaringan yang fleksibel dan kemampuan menangkap hubungan kompleks antar variabel, ANN mampu menghasilkan prediksi harga saham yang lebih presisi dibandingkan pendekatan alternatif semisal Support Vector Machine (SVM) atau Random Forest.

Adapun aspek keterbaruan (novelty) dalam penelitian ini terletak pada beberapa hal. Pertama, fokus penelitian diarahkan secara khusus pada saham ADMR, salah satu saham aktif di Bursa Efek Indonesia, yang belum banyak diteliti secara mendalam dalam konteks prediksi berbasis ANN. Kedua, penelitian ini mengedepankan pendekatan eksploratif terhadap pengaruh berbagai atribut data (fitur teknikal) terhadap akurasi prediksi harga saham, sehingga diharapkan dapat memberikan wawasan baru mengenai kombinasi fitur yang paling relevan untuk model ANN. Ketiga, pendekatan optimasi kinerja dilakukan melalui evaluasi nilai error secara cermat, mencakup metrik seperti Mean Absolute Error (MAE), Root Mean Square Error (RMSE), dan Mean Squared Error (MSE), untuk memastikan ketepatan model dalam melakukan prediksi. Terakhir, hasil penelitian ini juga dibandingkan dengan berbagai studi terdahulu, baik dari konteks pasar saham internasional maupun dari segi metode yang digunakan, guna memperkuat validitas dan kontribusi ilmiah dari penelitian ini.

Penelitian ini dikategorikan sebagai penelitian prediktif karena bertujuan menghasilkan estimasi nilai berdasarkan pola yang ditemukan dalam data historis. Pendekatan ini tidak hanya menggambarkan kondisi yang telah terjadi, tetapi juga berfokus pada bagaimana informasi masa lalu dapat digunakan untuk menghasilkan keluaran yang merepresentasikan kemungkinan kondisi di luar data yang telah diamati. Dalam hal ini, model Artificial Neural Network (ANN) berperan penting dalam mengenali struktur, tren, dan keteraturan dalam data harga saham ADMR. Model ini dilatih untuk memahami hubungan antar variabel dalam urutan waktu, sehingga mampu memberikan gambaran yang bersifat antisipatif terhadap pergerakan selanjutnya. Dengan memanfaatkan algoritma backpropagation dan pendekatan berbasis time-series, penelitian ini

menunjukkan karakteristik utama dari penelitian prediktif, yaitu kemampuan untuk memberikan estimasi berdasarkan pembelajaran dari data sebelumnya. Pendekatan ini sangat relevan untuk mendukung pengambilan keputusan di bidang keuangan yang memerlukan respons cepat dan berbasis data. Melalui kombinasi pendekatan teoritis ANN, penerapan algoritma backpropagation, serta analisis yang berorientasi pada akurasi prediksi, penelitian ini diharapkan dapat memberikan kontribusi nyata dalam pengembangan model peramalan harga saham yang andal di pasar modal Indonesia.

BAB III


DESAIN PENELITIAN

Rancangan penelitian adalah skema terstruktur yang memberikan panduan menyeluruh bagi peneliti, mencakup gambaran, struktur, serta tahapan pelaksanaan mulai dari identifikasi permasalahan hingga pemilihan teknik analisis. Menurut Asenahabi, (2019), desain penelitian merupakan rencana yang disusun peneliti sebagai pedoman pelaksanaan studi. (Sileyew, 2019) menyatakan bahwa desain penelitian merupakan bentuk kesiapan peneliti dalam menganalisis kelompok atau fenomena pada lingkungan aslinya. Selain itu (Margono, 2005) menegaskan bahwa desain penelitian juga berperan dalam menetapkan tanggung jawab atas setiap langkah yang dilakukan selama proses penelitian.

Penelitian ini mengadopsi pendekatan kuantitatif mengingat seluruh data yang dipakai bersifat numerik, yang kemudian dianalisis melalui metode statistik dengan metrik Mean Squared Error (MSE) (Lim et al., 2016). Secara esensial, analisis konten kuantitatif merupakan teknik penelitian yang mengidentifikasi atribut utama serta menyimpulkan temuan dari suatu konten. Pendekatan ini dirancang guna mengeksplorasi komunikasi secara sistematis melalui proses yang objektif, valid, konsisten, serta dapat diulang oleh peneliti lain. (Sarief et al., 2023).

3.1 Prosedur Penelitian

Peneliti melaksanakan serangkaian tahapan untuk memperoleh data dan menjawab pertanyaan penelitian, yang secara umum dikenal sebagai prosedur penelitian. Dalam studi ini, penulis menguraikan metode pengumpulan data, proses pengembangan sistem, serta tahapan eksperimen yang dilakukan. Penelitian ini bersifat eksperimental, dengan memanfaatkan data yang diperoleh melalui observasi maupun percobaan guna menghasilkan temuan yang dapat dibuktikan secara empiris. Jenis penelitian yang digunakan termasuk dalam kategori eksperimen dengan memanfaatkan data penjualan produk digital. Gambaran mengenai tahapan penelitian digambarkan pada Gambar 3.1:



Gambar 3. 1 Prosedur penelitian

(Dari olahan penulis)

Gambar 3.1 menunjukkan bahwa tahapan penelitian ini terdiri dari enam langkah pokok. Pertama, pengumpulan data untuk proses uji coba pada sistem. Kedua, rekayasa data dilakukan untuk mengorganisir informasi atau data yang telah dikumpulkan sesuai dengan kebutuhan penelitian. Ketiga, desain dan implementasi sistem merupakan inti dari program yang dilakukan secara prosedural untuk menjaga standar kualitas dan konsistensi pada sistem yang akan dirancang. Keempat, penulis melakukan eksperimen dengan pendekatan secara ilmiah dan dataset sebagai variabel input pada penelitian. Kelima, penulis melakukan evaluasi kinerja khusus pada model ANN sebagai model yang digunakan dan dirancang dalam prediksi harga saham pada penelitian ini. Tahap terakhir, selanjutnya penulis mengambil kesimpulan dari seluruh hasil penelitian untuk dokumentasi.

3.1. 1 Pengumpulan Data

Pengadaan data menjadi pilar krusial bagi berbagai macam studi, lantaran data berkualitas rendah berpotensi merusak validitas studi dan menghasilkan hasil yang kurang optimal (Juliandi & Manurung, 2014). Penelitian ini memanfaatkan data sekunder dari PT Adaro Minerals Tbk, yang diakses melalui situs <https://finance.yahoo.com/quote/ADMR.JK/history> untuk periode 28 November 2022 hingga 13 November 2025. Tambahan data sentimen pasar saham ADMR diperoleh dari Twitter melalui teknik web scraping.

Proses pengumpulan data dilaksanakan pada 27 November 2025, menghasilkan sekitar 706 record untuk setiap atribut. Pada data harga saham, atribut yang diperoleh mencakup *Date*, *Open*, *High*, *Low*, *Close*, serta *Volume*. Sementara itu, data sentimen Twitter menyediakan atribut seperti *created_at*, *username*, *full_text*, *reply_count*, *retweet_count*, *favorite_count*, *image_url*, dan *tweet_url*. Data harga saham dirangkum dalam Tabel 3.1, sedangkan data sentimen ADMR ditampilkan pada Tabel 3.2:

Tabel 3. 1 Data time series harga saham ADMR

Date	Open	High	Low	Close	Volume
11/28/2022	1649	1668	1577	1577	141,571,100
11/29/2022	1620	1620	1558	1563	136,449,100
11/30/2022	1563	1616	1544	1554	920,630,300
12/01/2022	1592	1649	1573	1620	210,495,500
12/02/2022	1625	1630	1596	1611	82,899,000
...
-n	-n	-n	-n	-n	-n

Kedua dataset yang digunakan memiliki karakteristik yang berbeda. Data harga saham bersifat numerik dan terstruktur, sedangkan data sentimen bersifat tidak terstruktur dan memerlukan transformasi sebelum digunakan dalam model prediksi. Kombinasi kedua jenis data ini memungkinkan penelitian untuk mengevaluasi pengaruh aspek teknis dan emosional pasar secara bersamaan dalam membangun model prediksi harga saham berbasis data sentimen.

Tabel 3. 2 Data sentiment pasar saham ADMR

created_at	username	full_text	reply_count
Thu May 22 07:41:36 +0000 2025	kanasudj	@kiranapunie terimakasih admr nya kak masih hold. fore nya udah masuk kak?	1
Thu May 22 04:16:38 +0000 2025	Valzkuy	@Valzkuy Bisa. Cup n handle udah kebentuk. Tinggal terbang aja kayak admr kemaren kemaren	0
Thu May 22 01:06:01 +0000 2025	(tidak tercantum)	https://t.co/3goV3F1Yug Saham swing \$ASRI cl < 145 ... Disclaimer On	0
Wed May 21 14:51:21 +0000 2025	rinaldtrader	Sore yg ok kepilih \$admr \$pwon \$asri \$antm	0
...
-n	-n	-n	-n
retweet_count	favorite_count	image_url	tweet_url
0	0	-	https://x.com/undefined/status/1925456998562431125
0	0	-	https://x.com/undefined/status/1925405415690719522
0	2	-	https://x.com/undefined/status/1925357447176417711
0	0	-	https://x.com/undefined/status/1925202759965712730
...
-n	-n	-n	-n

Tabel 3. 3 Deskripsi data harga dan sentiment pasar Saham ADMR

Atribut	Deskripsi
Date	Tanggal perdagangan
Open	Harga saham pada saat pembukaan pasar
High	Harga tertinggi selama sesi perdagangan
Low	Harga terendah selama sesi perdagangan
Close	Harga penutupan pasar
Volume	Jumlah saham yang diperdagangkan pada hari tersebut
Atribut	Deskripsi
created at	Waktu tweet dibuat
username	Nama pengguna yang mempublikasikan tweet
full text	Isi atau konten tweet
reply count	Jumlah balasan terhadap tweet
retweet count	Jumlah retweet
favorite count	Jumlah tweet yang disukai (likes)
image url	Tautan gambar (jika ada)
tweet url	Tautan asli tweet di platform X (Twitter)

3.1. 2 Rekayasa Data

Langkah berikutnya melibatkan beraneka ragam upaya memoles data agar dataset siap pakai dan berkualitas tinggi untuk keperluan analisis serta pembuatan model prediksi menggunakan model ANN berbasis data time series dan data sentimen saham ADMR. Proses pengolahan data dilakukan secara bertahap dan sistematis mencakup beberapa langkah utama.

Tahap pertama adalah cleaning data, yaitu proses pemeriksaan dan pembersihan dataset dari duplikasi, missing value, noise, serta karakter teks yang tidak relevan seperti spam, URL panjang, simbol, dan emotikon yang tidak memiliki nilai analitis. Untuk data sentimen dari Twitter, proses cleaning dilakukan melalui normalisasi teks, termasuk lowercasing, penghapusan tanda baca, tokenisasi, serta penghilangan stopwords agar konten tetap fokus pada makna inti. Sedangkan untuk data harga saham, proses cleaning memastikan tidak terdapat nilai kosong pada atribut harga dan volume yang dapat mengganggu struktur data time-series. Tahap berikutnya adalah pelabelan sentimen menggunakan model Indonesia RoBERTa, yang merupakan model NLP berbasis Transformer yang telah dilatih secara khusus untuk pemrosesan bahasa Indonesia (Sihombing & Situmorang, 2024). Model ini menghasilkan klasifikasi sentimen dalam tiga kategori, yaitu positif dengan nilai satu (1), negatif dengan nilai minus satu (-1), dan netral dengan nilai nol (0), berdasarkan konteks dan makna setiap tweet yang berkaitan dengan saham ADMR.

Proses pelabelan ini memberikan representasi psikologis pasar yang lebih terukur dan dapat diubah menjadi variabel numerik sebagai input model.

Tabel 3. 4 Hasil pembersihan dan pelebelan data sentimen

Tanggal	Teks	Sentimen Label Raw	Sentimen Score Confidence	Sentimen Mark
5/21/2025	Sore yg ok kepilih \$admr \$pwon \$asri \$antm	Neutral	0.997904062	0
5/21/2025	IHSG Hari Ini: Reli ke 7.142 INCO ADMR AKRA Pimpin Kenaikan LQ45 - https://t.co/FmrPI9xqoi https://t.co/ItXKWcIZRz	Neutral	0.998143077	0
5/21/2025	Admr naik ini perlu buat syukuran ngak sih	Neutral	0.948393524	0
5/21/2025	Calon BSJP hari ini \$ANTM \$LAJU \$BRPT \$ADMR Disclaimer On	Neutral	0.999026418	0
5/20/2025	@WOLF_of_IHSG Semoga admr ikut cakeep jg	Positive	0.769458771	1
5/20/2025	@WOLF_of_IHSG Admr nya ndak kuat (atau belum)	Negative	0.99883014	-1
5/22/2025	@kiranapunie terimakasih admr nya kak masih hold. fore nya udah masuk kak?	Neutral	0.630820751	0
...
<i>-n</i>	<i>-n</i>	<i>-n</i>	<i>-n</i>	<i>-n</i>

Langkah selanjutnya adalah perhitungan sentimen (*sentiment count*), yaitu menghitung intensitas sentimen per tanggal perdagangan dengan proses agregasi. Perhitungan dilakukan dengan merata-ratakan jumlah sentimen positif, negatif, dan netral untuk setiap tanggal sehingga menghasilkan indeks sentimen harian yang merepresentasikan pola persepsi publik terhadap saham ADMR. Hasil dari perhitungan sentiment disajikan pada Tabel berikut ini:

Tabel 3. 5 Hasil perhitungan data sentimen (merata-ratakan)

[illegible]

Pada dataset sentimen yang digunakan dalam penelitian ini, hasil klasifikasi model berupa kategori positif, netral, dan negatif diperlakukan sebagai data berskala ordinal, karena kategori-kategori tersebut memiliki urutan tingkat persepsi tetapi belum memiliki makna jarak numerik yang pasti antar kelas. Dalam konteks analisis statistik dan pemodelan multivariat, data berskala ordinal seperti ini pada dasarnya lebih tepat diolah dengan teknik nonparametrik, namun penggunaan metode nonparametrik seringkali menimbulkan kesulitan praktis, antara lain karena rumusan matematis yang lebih kompleks dan keterbatasan dukungan perangkat lunak (Sartika, 2010). Agar data sentimen dapat dimasukkan sebagai variabel numerik dalam model prediksi berbasis Artificial Neural Network (ANN), penelitian ini mentransformasi skala ordinal tersebut menjadi skala interval menggunakan pendekatan Metode Successive Interval (MSI) yang dalam psikometrika dikenal sebagai salah satu teknik penskalaan untuk mengatasi keterbatasan skala ordinal (Sartika, 2010). Sejalan dengan kajian literatur terbaru yang menunjukkan bahwa MSI efektif meningkatkan akurasi pengukuran dan memperluas penerapan analisis statistik pada berbagai bidang melalui konversi data ordinal ke interval (Izzati, 2025), penelitian ini melakukan transformasi dengan mengubah proporsi kumulatif tiap kategori sentimen menjadi nilai pada kurva normal baku sehingga diperoleh skor interval yang merepresentasikan jarak antar kategori secara lebih bermakna dan dapat diproses dengan teknik parametrik serta diintegrasikan secara langsung dengan data harga saham dalam pemodelan ANN.

Tahap terakhir adalah penggabungan data sentimen dengan data historis harga saham berdasarkan tanggal yang sama. Proses ini menghasilkan dataset multimodal yang terdiri dari informasi teknikal saham (*Open, High, Low, Close, Volume*) dan informasi non-teknikal berupa skor sentimen pasar. Penggabungan ini dilakukan untuk memastikan model ANN dapat mempelajari hubungan antara dinamika harga saham dan perubahan sentimen pasar secara simultan.

Tabel 3. 6 Hasil penggabungan data harga saham dan sentimen pasar ADMR

Date	Open	High	Low	Close	Volume	Sentimen
11/28/2022	1649	1668	1577	1577	141,571,100	0
11/29/2022	1620	1620	1558	1563	136,449,100	0
11/30/2022	1563	1616	1544	1554	920,630,300	0
12/01/2022	1592	1649	1573	1620	210,495,500	0
12/02/2022	1625	1630	1596	1611	82,899,000	0
12/05/2022	1620	1639	1596	1606	85,842,900	0
12/06/2022	1601	1611	1568	1568	67,066,800	0
12/07/2022	1592	1592	1511	1573	72,375,900	-0.5
12/08/2022	1573	1601	1525	1601	85,373,500	0
...
-n	-n	-n	-n	-n	-n	-n


Tahap berikutnya adalah normalisasi data untuk menyamakan skala setiap variabel sebelum digunakan sebagai input model ANN. Proses ini penting karena setiap atribut memiliki rentang nilai berbeda, sehingga tanpa normalisasi model dapat memberikan bobot berlebih pada variabel tertentu. Penelitian ini menerapkan teknik Min-Max Scaling untuk mengonversi data numerik ke dalam rentang 0-1, sehingga seluruh variabel fitur memiliki skala yang proporsional. Proses normalisasi ini juga berfungsi untuk meningkatkan efisiensi proses pelatihan model serta meminimalkan potensi overfitting. Hasil dari normalisasi tersebut disajikan dalam Tabel 3.7 berikut:

Tabel 3. 7 Data harga saham setelah dinormalisasi

Date	Open	High	Low	Close	Volume	Sentimen
11/28/2022	1	1	0.776471	0.348485	0.087286	1
11/29/2022	0.662791	0.368421	0.552941	0.136364	0.081285	1
11/30/2022	0	0.315789	0.388235	0	1	1
12/01/2022	0.337209	0.75	0.729412	1	0.168035	1
12/02/2022	0.720930	0.5	1	0.863636	0.018548	1
12/05/2022	0.662791	0.618421	1	0.787879	0.021997	1
12/06/2022	0.441860	0.25	0.670588	0.212121	0	1
12/07/2022	0.337209	0	0	0.287879	0.006220	0
12/08/2022	0.116279	0.118421	0.164706	0.712121	0.021447	1
...
-n	-n	-n	-n	-n	-n	-n

3.1.3 Desain sistem

Gambar 3.2 menunjukkan alur proses desain sistem dalam penelitian ini. Ini penjelasan mengenai mekanisme sistem dalam meramalkan harga saham menggunakan pendekatan model jaringan saraf tiruan (ANN).



Gambar 3. 2 Rancangan sistem
(Dari olahan penulis)

A. Data harga dan sentiment pasar saham ADMR

Di tahap pendahuluan penelitian, data pergerakan harga saham ADMR dan data sentimen pasar dikumpulkan sebagai bahan dasar untuk mengembangkan sistem prediksi harga saham. Data harga yang dimanfaatkan mencakup nilai pembukaan (*open*), penutupan (*close*), tertinggi (*high*), terendah (*low*), serta volume perdagangan harian. Seluruh data ini kemudian dikonversi ke dalam format Comma Separated Values (CSV) agar dapat dengan mudah diproses dan dianalisis secara komputasional. Format data ini disajikan pada Tabel 3.8 sebagai gambaran awal struktur data yang digunakan dalam penelitian. Dalam upaya memperoleh pemahaman yang lebih komprehensif terkait dinamika/fluktuasi pergerakan harga saham ADMR, penelitian ini tak sebatas memanfaatkan data harga secara teknikal, melainkan juga mengintegrasikan data sentimen pasar. Data sentimen diperoleh dari website twitter terkait dengan ulasan sentiment pasar saham ADMR. Integrasi antara data harga dan sentimen ini diharapkan mampu mencerminkan dua sisi utama dalam dinamika pasar: faktor teknikal yang terukur melalui harga historis, dan faktor psikologis pasar yang tergambar melalui opini dan reaksi investor.

Sebelum digunakan dalam model pembelajaran mesin, seluruh data harus melalui tahap pra-pemrosesan. Tahapan ini mencakup normalisasi nilai harga untuk menormalkan skala data, membersihkan anomali serta noise dari teks sentimen, serta mengubah data

tekstual menjadi bentuk numerik melalui pendekatan seperti *sentiment scoring* atau *word embedding*. Langkah pengolahan ini krusial agar data input ke sistem benar-benar bersih, relevan, dan optimal untuk tahap pelatihan model prediksi. Selanjutnya, karena data yang digunakan bersifat deret waktu (time-series), maka ketepatan waktu pencatatan menjadi hal yang sangat krusial. Oleh sebab itu, dilakukan sinkronisasi antara data harga dan data sentimen berdasarkan tanggal dan waktu yang sama, sehingga memungkinkan analisis paralel terhadap pengaruh sentimen pada fluktuasi harga saham. Dengan demikian, setiap informasi sentimen yang tercatat pada hari tertentu dapat dikaitkan secara langsung dengan pergerakan harga saham ADMR pada periode yang sama, menciptakan dasar yang kuat dalam membangun model prediksi yang akurat dan kontekstual.

Tabel 3. 8 Detail data harga saham dan sentimen pasar ADMR

No	Atribut	Rentang Nilai	Tipe Data	Satuan
1	<i>Date</i>	-	<i>Date</i>	-
2	<i>Open</i>	1010 - 2999	<i>Numeric</i>	IDR
3	<i>High</i>	1021 - 3102	<i>Numeric</i>	IDR
4	<i>Low</i>	878 - 2970	<i>Numeric</i>	IDR
5	<i>Close</i>	951 - 3036	<i>Numeric</i>	IDR
7	<i>Volume</i>	1049976 - 199601827	<i>Numeric</i>	IDR
8	Sentimen	(-1) - 1	<i>Numeric</i>	-

Berdasarkan Tabel 3.8, terdapat delapan atribut yang digunakan sebagai data masukan dalam proses prediksi, yang mencakup penggabungan antara data harga saham dan sentimen pasar. Atribut-atribut tersebut meliputi Date, Open, High, Low, Close, Volume, dan Sentimen. Atribut Date merepresentasikan tanggal harga saham pada hari yang bersangkutan dengan tipe data Datetime. Sementara itu, atribut Open menunjukkan harga pembukaan harian dengan data berbentuk bilangan, sama dengan fitur lainnya, rentangnya mulai 1.010 hingga 2.999 IDR. Adapun atribut High menggambarkan harga tertinggi yang dicapai dalam satu hari perdagangan, dengan kisaran 1.021 hingga 3.102 IDR sementara Low merepresentasikan harga terendah dengan rentang antara 878 hingga 2970 IDR. Atribut Close menunjukkan harga penutupan harian yang juga menjadi harga pembuka hari berikutnya, dengan nilai berkisar antara 951 hingga 3036. Sentimen adalah

data yang menggambarkan kondisi pasar saham ADMR secara global yang di olah berdasarkan analisis sentiment, dengan nilai berkisar antara minus satu (-1) hingga satu (1).

Untuk mengatasinya, normalisasi data perlu dilakukan sebagai tahap penting sebelum dataset diproses oleh model. Normalisasi ini berfungsi menyamakan skala tiap atribut sehingga nilainya berada pada rentang yang konsisten dan sebanding, umumnya dibatasi pada interval 0 sampai 1. tanpa mengubah struktur atau makna dasar dari data tersebut. Teknik ini membantu algoritma ANN dalam mempercepat proses pelatihan, meminimalkan kesalahan numerik, serta meningkatkan stabilitas perhitungan gradien dalam proses backpropagation. Pada penelitian ini metode normalisasi yang digunakan adalah Min-Max Scaling menjadi metode yang paling sering digunakan pada data yang memiliki rentang nilai pasti seperti dalam penelitian ini. Dengan menerapkan normalisasi, setiap atribut akan memberikan kontribusi yang seimbang terhadap pembelajaran jaringan, sehingga dapat meningkatkan akurasi dan efisiensi prediksi harga saham ADMR yang berbasis data historis dan sentimen pasar.

B. Preprocessing Data

Tahap preprocessing merupakan bagian krusial dalam pengolahan data sebelum dimasukkan ke model prediksi. Pada fase ini, data yang telah terkumpul melalui proses pembersihan dan transformasi agar lebih sesuai dan efektif digunakan oleh model Artificial Neural Network (ANN).

Salah satu langkah inti dalam preprocessing adalah normalisasi, yaitu penyesuaian skala nilai numerik ke rentang tertentu supaya setiap fitur memiliki bobot kontribusi yang lebih seimbang selama pelatihan jaringan. Normalisasi dilakukan untuk mencegah fitur berskala besar mendominasi proses pembelajaran, sekaligus membantu mempercepat konvergensi ketika model belajar dari data.

Dalam penelitian ini, teknik normalisasi yang diterapkan adalah Min-Max Scaling, yakni metode yang menyesuaikan nilai pada setiap atribut sehingga dipetakan ke rentang 0 sampai 1. Metode ini dipilih karena mempertahankan distribusi asli data dan sangat efektif dalam mengatasi perbedaan skala antar fitur. Adapun rumus normalisasi yang digunakan adalah sebagai berikut (Urva *et al.*, 2023):

$$x_{norm} = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (1)$$

Dimana:

x = nilai data asli (sebelum dilakukan normalisasi).

x_{norm} = merupakan nilai data setelah proses normalisasi.

$\min(x)$ = nilai paling kecil dari seluruh data pada atribut yang dinormalisasi.

$\max(x)$ = nilai paling besar dari seluruh data pada atribut yang dinormalisasi.

Penerapan normalisasi ini menjadi sangat relevan karena pada data harga saham ADMR, terdapat atribut yang memiliki rentang nilai yang sangat besar, seperti Volume, yang mencapai angka miliaran rupiah, sementara atribut lainnya seperti Sentimen hanya memiliki nilai berkisar antara minus satu (-1) hingga satu (1). Tanpa proses normalisasi, atribut dengan skala besar seperti Volume dapat mendominasi proses pelatihan jaringan dan menyebabkan model kesulitan dalam mengenali pola dari fitur yang memiliki skala kecil.

Dalam konteks data saham ADMR tahun 2025, berdasarkan pemantauan data historis dan laporan resmi Bursa Efek Indonesia, tidak ditemukan adanya peristiwa suspend perdagangan sepanjang tahun tersebut. Hal ini menunjukkan bahwa data harga dan volume saham tersedia secara utuh tanpa adanya celah hari perdagangan akibat penghentian sementara. Dengan demikian, dataset pada penelitian ini relatif bersih dari nilai-nilai kosong (null) yang biasanya muncul akibat suspend, sehingga tidak memerlukan proses imputasi data akibat ketidakhadiran nilai (“Laporan Perdagangan Saham Harian Tahun 2025,” 2025). Namun demikian, proses validasi tetap dilakukan untuk memastikan data terbebas dari nilai yang hilang (missing value) maupun outlier yang terlalu ekstrem, sehingga kinerja model tidak terganggu. Misalnya, pada saat momen tertentu seperti pembagian dividen oleh ADMR pada 2 Juni 2025, volume perdagangan dapat meningkat drastis, sehingga perlu dilakukan penanganan khusus seperti capping atau transformasi logaritmik sebelum proses normalisasi, jika nilai tersebut teridentifikasi sebagai anomaly (“Pengumuman Pembagian Dividen Tunai Tahun Buku 2024,” 2025).

Setelah dipastikan tidak terdapat missing value atau outlier ekstrem yang merusak distribusi data, barulah dilakukan normalisasi dilakukan dengan metode Min–Max Scaling untuk menyeragamkan rentang nilai data. Melalui proses ini, seluruh atribut—mulai dari harga pembukaan (Open), harga tertinggi (High), harga terendah (Low), harga penutupan (Close), volume transaksi (Volume), hingga skor sentimen pasar—dibuat berada pada

skala yang sebanding sehingga kontribusinya lebih seimbang dalam pemodelan yaitu antara 0 hingga 1. Dengan penerapan preprocessing yang baik, data menjadi lebih siap untuk diolah oleh model ANN, yang sensitif terhadap skala input. Selain itu, proses ini juga membantu menjaga integritas pola historis dalam data, memastikan bahwa ANN dapat belajar secara optimal dalam memprediksi harga saham berdasarkan input harga dan sentimen pasar. Preprocessing yang tepat menjadi fondasi penting dalam keseluruhan proses end-to-end peramalan harga saham yang dibangun dengan metode kecerdasan buatan.

C. Algoritma ANN

Artificial Neural Network (ANN) adalah sistem pengolahan informasi yang konsepnya diadaptasi dari mekanisme kerja jaringan saraf biologis pada otak manusia. ANN dikembangkan untuk meniru kemampuan otak dalam mempelajari pola dan melakukan pembelajaran dari data atau pengalaman sebelumnya. Dalam penelitian ini, ANN dimanfaatkan sebagai metode utama untuk memperkirakan harga saham ADMR dengan menggabungkan data historis harga serta sentimen pasar. Pemilihan ANN didasari kemampuannya dalam memodelkan keterkaitan nonlinier yang kompleks di antara variabel pasar yang bersifat dinamis dan sering kali sulit dijelaskan dengan pendekatan linear. Menurut Da Silva (2017), ANN terdiri dari tiga lapisan utama, yaitu, lapisan input, lapisan tersembunyi (hidden layer), dan lapisan output. Lapisan input berfungsi menerima data awal berupa fitur seperti harga pembukaan (open), harga tertinggi (high), harga terendah (low), harga penutupan (close), serta volume transaksi dan indeks sentimen pasar. Selanjutnya, lapisan tersembunyi menjalankan pemrosesan internal dengan menyusun pola berdasarkan kombinasi bobot dan aktivasi dari setiap neuron. Lapisan ini merupakan inti dari pembelajaran jaringan karena di sinilah model menemukan representasi tersembunyi dari data yang tidak tampak secara langsung di permukaan. Terakhir, lapisan output mengeluarkan hasil prediksi berupa estimasi harga penutupan saham pada periode tertentu.

Secara arsitektural, neuron-neuron dalam ANN dikelompokkan ke dalam lapisan-lapisan tersebut. Berdasarkan jumlah lapisan tersembunyi yang digunakan, ANN diklasifikasikan ke dalam dua jenis utama, yaitu jaringan satu lapisan (single-layer

network) dan jaringan multilapisan (multi-layer network). Jaringan satu lapisan menghubungkan input langsung ke output tanpa melalui proses abstraksi, sehingga kurang efektif untuk masalah yang kompleks. Sebaliknya, arsitektur jaringan multilapis yang diterapkan pada penelitian ini menggunakan satu atau beberapa hidden layer, sehingga model mampu mempelajari pola yang lebih kompleks secara lebih mendalam dan meningkatkan ketelitian prediksi, termasuk pada dinamika harga saham yang dipengaruhi beragam faktor internal maupun eksternal. Setelah itu, jaringan diinisialisasi dengan bobot awal secara acak, lalu turunan (gradien) dari fungsi error dihitung sebagai dasar untuk memperbarui bobot-bobot tersebut, sehingga kinerja jaringan dapat diperbaiki melalui persamaan berikut. (Sivanandam & Paulraj, 2009):

$$net = w_0 + \sum_{i=1}^n x_i w_i \quad (2)$$

Di mana:

net = nilai hasil perhitungan (output) pada node/neuron yang sedang diproses.

w_0 = nilai bias pada node/neuron yang bersangkutan.

i = indeks penjumlahan yang berjalan dari 1 hingga n

x_i = nilai input ke- i yang berasal dari node/lapisan sebelumnya.

w_i = bobot koneksi yang menghubungkan input ke- i dengan node/neuron yang sedang dihitung

n = jumlah total fitur/variabel input yang digunakan.

Selanjutnya, fungsi transfer Rectified Linear Unit (ReLU) digunakan untuk mentransformasikan nilai masukan menjadi nilai keluaran pada neuron. Fungsi ReLU bekerja dengan mempertahankan nilai input positif dan mengubah nilai input negatif menjadi nol, sehingga mampu meningkatkan efisiensi proses pelatihan dan mengurangi masalah vanishing gradient. Secara matematis, fungsi ReLU dirumuskan sebagai berikut:

$$f(x) = \max(0, x) \quad (3)$$

Di mana:

x = input ke neuron

Dalam konteks prediksi harga saham ADMR, kemampuan ANN untuk mengolah data dalam jumlah besar, menyesuaikan bobot secara dinamis, serta menangani data nonlinier menjadi sangat relevan. Pasar saham adalah sistem yang tidak sepenuhnya

deterministik dan sangat dipengaruhi oleh psikologi massa, kondisi makroekonomi, dan kejadian eksternal. Oleh sebab itu, penerapan ANN berarsitektur multilapisan dengan fungsi aktivasi nonlinier, seperti Rectified Linear Unit (ReLU), dapat membantu model menemukan pola-pola tersembunyi pada data historis maupun sentimen yang umumnya sulit ditangkap oleh pendekatan statistik konvensional. Mekanisme pembelajaran pada ANN pada dasarnya mencakup dua tahap inti, yaitu *forward propagation* dan *backpropagation*. Pada fase *forward propagation*, data masukan dialirkan melewati setiap lapisan neuron hingga menghasilkan keluaran berupa prediksi awal. Prediksi tersebut kemudian disejajarkan dengan nilai aktual untuk menghitung besarnya kesalahan (loss), yang menjadi dasar perbaikan model pada tahap berikutnya. Tahap selanjutnya adalah *backpropagation*, yaitu proses di mana kesalahan ini dikembalikan ke jaringan untuk menyesuaikan bobot neuron dengan menggunakan algoritma pembaruan bobot berdasarkan nilai gradien. Proses ini dilakukan secara berulang-ulang (iteratif) hingga nilai kesalahan pada prediksi menurun secara signifikan dan model mencapai konvergensi.

Dalam penelitian ini, beberapa parameter penting telah diatur untuk mengoptimalkan performa model ANN, antara lain: *learning rate* sebesar 0.001, optimizer Adam yang dikenal efektif karena mampu menyesuaikan pembaruan bobot secara adaptif, serta fungsi aktivasi ReLU yang mampu mempercepat konvergensi dan menghindari masalah *vanishing gradient*. Kombinasi parameter ini dirancang untuk memberikan keseimbangan antara kecepatan pelatihan dan ketepatan prediksi. Lebih jauh, karena objek penelitian adalah prediksi harga saham ADMR, maka data yang digunakan mencakup indikator harga historis dan data sentimen pasar yang memengaruhi persepsi investor terhadap saham tersebut. Data sentimen dikumpulkan dari beragam kanal, seperti berita ekonomi, media sosial, maupun forum diskusi saham, lalu diolah sehingga dapat direpresentasikan sebagai nilai atau skor numerik. Integrasi antara data numerik dan sentimen ini mencerminkan pendekatan holistik dalam memodelkan pergerakan harga saham, yang tidak hanya berdasarkan data teknikal tetapi juga mempertimbangkan faktor psikologis pasar.

Untuk memperoleh hasil prediksi yang optimal, pelatihan jaringan dilakukan secara berulang dalam satu siklus penuh. Jaringan awal diinisialisasi dengan bobot acak, lalu

dilakukan perhitungan gradien dari fungsi kesalahan (*loss function*) untuk mengarahkan proses pembaruan bobot. Bobot-bobot ini akan disesuaikan secara bertahap menggunakan rumus pembaruan berbasis gradien descent hingga diperoleh model berakurasi tinggi untuk kebutuhan peramalan harga saham ADMR di masa mendatang. Dengan pendekatan ANN, model yang dikembangkan diharapkan mampu merespons perubahan kondisi pasar secara lebih fleksibel serta menghasilkan prediksi yang lebih tepat dibandingkan metode-metode konvensional. Kemampuan ANN dalam mempelajari pola yang rumit sekaligus melakukan generalisasi pada data baru yang belum pernah ditemui sebelumnya membuatnya sering dipandang sebagai salah satu metode yang efektif untuk membangun sistem prediksi harga saham berbasis kecerdasan buatan.

D. Prediksi harga saham

Dalam penelitian ini, performa model dalam memprediksi harga saham dievaluasi menggunakan beberapa indikator, yaitu Mean Squared Error (MSE), Mean Absolute Error (MAE), serta koefisien determinasi (R^2).

Pengukuran MSE dirumuskan sebagai berikut:

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (4)$$

Di mana:

MSE = nilai kesalahan kuadrat rata-rata yang digunakan untuk mengukur selisih antara hasil prediksi dan data aktual.

n = jumlah total data/observasi yang dihitung dalam evaluasi..

Y_i = nilai aktual atau nilai yang teramati pada data ke- i

\hat{Y}_i = nilai hasil prediksi model pada data ke- i .

MSE digunakan untuk menilai seberapa besar rata-rata kesalahan prediksi, dengan penekanan yang lebih kuat pada error yang nilainya sangat besar atau ekstrem. Semakin kecil nilai MSE, umumnya semakin baik kemampuan model dalam menghasilkan prediksi yang mendekati data aktual. Setelah itu, MAE dipakai untuk menghitung rata-rata selisih absolut antara nilai prediksi dan nilai sebenarnya, yang selanjutnya dapat dituliskan dalam bentuk persamaan berikut:

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i| \quad (5)$$

MAE memberikan interpretasi yang lebih intuitif karena kesalahan dihitung dalam satuan yang sama dengan data asli. Nilai MAE yang lebih kecil menunjukkan bahwa prediksi model semakin mendekati nilai aktual. Selain itu, kinerja model juga dievaluasi menggunakan Koefisien Determinasi (R^2) yang dirumuskan sebagai berikut:

$$R^2 = 1 - \frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2} \quad (6)$$

di mana:

R^2 = koefisien determinasi

\bar{Y} = nilai mean dari observasi (data sebenarnya)

R^2 digunakan untuk menggambarkan sejauh mana model mampu menjelaskan variasi yang muncul pada data penjualan. Jika nilai R^2 makin mendekati 1, berarti model semakin baik dalam memprediksi, sedangkan nilai yang mendekati 0 atau bahkan negatif menandakan model belum cukup mampu merepresentasikan variasi data secara memadai.

3.1.3. 1 Ekstraksi Fitur

Ekstraksi fitur bertujuan menyederhanakan dataset dengan mengurangi jumlah fitur yang digunakan. Tahap ini dijalankan setelah proses rekayasa data, yaitu saat atribut-atribut yang akan dijadikan dasar pengujian telah ditetapkan. Rincian prosedur ekstraksi fitur dijelaskan lebih lanjut pada Tabel 3.9.

Tabel 3. 9 Penyaringan fitur kunci

Atribut	Tipe data	Keterangan
<i>Date</i>	<i>Date</i>	-
<i>Open</i>	<i>Numeric</i>	-
<i>High</i>	<i>Numeric</i>	-
<i>Low</i>	<i>Numeric</i>	-
<i>Close</i>	<i>Numeric</i>	-
<i>Volume</i>	<i>Numeric</i>	-
Sentimen	<i>Numeric</i>	Ditambahkan

Tabel 3.9 di atas memperlihatkan ada tujuh fitur dalam studi ini, satu fitur yaitu sentimen ditambahkan untuk mengetahui kondisi pasar saham sebagai salah satu faktor yang mempengaruhi harga saham.

3.1.4 Implementasi Sistem

Dasar dari model ANN dibangun dari neuron (node) buatan yang saling terhubung, dan seluruh jaringan tersusun dari kumpulan node tersebut. Dalam proses kerjanya, neuron buatan menjalankan tiga operasi inti: perkalian, penjumlahan, dan aktivasi.

Pada setiap neuron, masing-masing nilai input diberi bobot, sehingga input akan dikalikan dengan bobot terkait terlebih dahulu. Hasil perkalian tersebut kemudian dijumlahkan bersama nilai bias, lalu dilewatkan ke fungsi aktivasi sebelum akhirnya diteruskan menjadi keluaran (output) ke lapisan berikutnya atau ke output akhir jaringan.

3.1.5 Eksperimen

Tabel 3. 10 Skenario Eksperimen Model ANN

Model	Variabel Input	Variabel Target	Kode	Hidden Layer	Neuron Setiap Layer	Rasio Data	Nama Pelatihan
BPNN + Sentimen	Selain Open	Open	A	1	7-32-1	80:20	BPNN-A1
				2	7-32-16-1	80:20	BPNN-A2
	Selain High	High	B	1	7-32-1	80:20	BPNN-B1
				2	7-32-16-1	80:20	BPNN-B2
	Selain Low	Low	C	1	7-32-1	80:20	BPNN-C1
				2	7-32-16-1	80:20	BPNN-C2
	Selain Close	Close	D	1	7-32-1	80:20	BPNN-D1
				2	7-32-16-1	80:20	BPNN-D2
BPNN tanpa Sentimen	Selain Open	Open	A	1	6-32-1	80:20	BPNN-A1
				2	6-32-16-1	80:20	BPNN-A2
	Selain High	High	B	1	6-32-1	80:20	BPNN-B1
				2	6-32-16-1	80:20	BPNN-B2
	Selain Low	Low	C	1	6-32-1	80:20	BPNN-C1
				2	6-32-16-1	80:20	BPNN-C2
	Selain Close	Close	D	1	6-32-1	80:20	BPNN-D1
				2	6-32-16-1	80:20	BPNN-D2

Tahap eksperimen pada penelitian ini dilaksanakan dengan memanfaatkan Visual Studio Code sebagai lingkungan pengembangan, serta bahasa pemrograman Python untuk membangun dan menjalankan model ANN dalam memprediksi harga saham pada periode mendatang. Setelah model menghasilkan nilai prediksi, kinerjanya dievaluasi dengan menghitung tingkat kesalahan menggunakan metrik Mean Squared Error (MSE). MSE mengukur rata-rata kuadrat selisih antara nilai prediksi dan nilai aktual, sehingga kesalahan yang besar akan memperoleh penalti lebih tinggi dalam penilaian performa model.

Dari Tabel 3.10 menunjukkan sekitar delapan skenario eksperimen yaitu, BPNN-A1 sampai dengan BPNN-D2 dalam memprediksi harga saham ADMR berdasarkan model ANN. Selanjutnya, penentuan atribut Open, High, Low sebagai variabel target didasarkan pada Fluktuasi harga saham dapat berlangsung sangat cepat, menyebabkan nilai saham tiba-tiba melonjak atau anjlok dalam waktu yang singkat (Aqila *et al.*, 2019). Sedangkan, penentuan atribut Close sebagai variabel target didasari oleh hasil penelitian oleh Sahi, (2023) yang mana penggunaan atribut tersebut merupakan model terbaik untuk memprediksi harga dalam konteks data time series dengan menggunakan dua hidden layer. Selain itu, pemilihan Sentimen sebagai variabel target didasarkan pada hasil penelitian Bailey, (2005) yang menyatakan bahwa sentimen pasar memberikan pengaruh signifikan terhadap pergerakan harga saham.

Selanjutnya, penentuan jumlah hidden layer pada penelitian ini merujuk pada pandangan Fausett, (1994) yang menyatakan bahwa satu lapisan tersembunyi pada jaringan saraf tiruan pada dasarnya sudah memadai untuk menghasilkan keluaran yang sesuai dengan target. Pernyataan tersebut mengindikasikan bahwa arsitektur jaringan yang relatif sederhana pun sering kali dapat bekerja efektif pada banyak kasus. Namun, perspektif yang berbeda dikemukakan oleh Thomas *et al.*, (2017) yang menilai bahwa penambahan satu hidden layer lagi—sehingga menjadi dua lapisan tersembunyi—sering kali mampu meningkatkan hasil. Menurut mereka, struktur yang sedikit lebih kompleks memberi jaringan kapasitas yang lebih besar untuk menangkap pola-pola data yang lebih rumit.

Dalam penelitian ini, jumlah neuron pada tiap lapisan ditetapkan dengan mempertimbangkan bentuk data serta tingkat kompleksitas pola yang ingin dipelajari oleh model. Pada skema BPNN yang memanfaatkan sentimen, lapisan input menggunakan 7 neuron karena menyesuaikan jumlah fitur yang dipakai, yakni Open, High, Low, Close, Volume, Sentimen, dan Date yang telah diubah ke format numerik. Model kemudian diuji menggunakan dua rancangan arsitektur. Rancangan pertama memakai konfigurasi 7–32–1, yang berarti 7 neuron pada input layer, 32 neuron pada satu hidden layer, serta 1 neuron pada output layer untuk menghasilkan prediksi harga. Rancangan kedua dibuat lebih mendalam dengan struktur 7–32–16–1, yaitu menambahkan hidden layer kedua berisi 16 neuron agar jaringan memiliki kapasitas lebih besar dalam menangkap hubungan nonlinier yang lebih kompleks antara indikator teknikal dan pergeseran sentimen pasar.

Sementara itu, pada model BPNN tanpa sentimen, lapisan input menggunakan total 6 neuron, menyesuaikan dengan atribut teknikal saja, yaitu Open, High, Low, Close, Volume, dan Tanggal. Dua arsitektur yang digunakan adalah 6–32–1 dan 6–32–16–1, mengikuti struktur yang sama seperti model bersentimen, namun tanpa variabel sentimen sebagai input. Pemilihan konfigurasi ini dibuat untuk membandingkan kemampuan model dengan tingkat kompleksitas yang berbeda, serta mengamati sejauh mana penambahan informasi sentimen memengaruhi kualitas prediksi harga saham.

3.2 Research Instrument

Tabel 3.11 menyajikan parameter-parameter yang digunakan dalam penelitian ini, meliputi variabel bebas, variabel perantara (intervening/penghubung), serta variabel terikat. Penelitian ini menitikberatkan pada variabel terikat, yaitu variabel yang nilainya dipengaruhi oleh variabel bebas. Dalam konteks penelitian ini, nilai error diposisikan sebagai variabel terikat.

Tabel 3. 11 Variabel penelitian

Independen Variable	Proses Utama	Intervening Variable	Variabel Independen
Atribut dataset harga dan sentimen pasar saham ADMR	ANN	Prediksi harga saham	Nilai akurasi MSE-Based

Penelitian ini menekankan pembahasan pada variabel terikat, yaitu variabel yang muncul sebagai akibat dari pengaruh variabel bebas. Berdasarkan rancangan penelitian, nilai error ditetapkan sebagai variabel terikat.

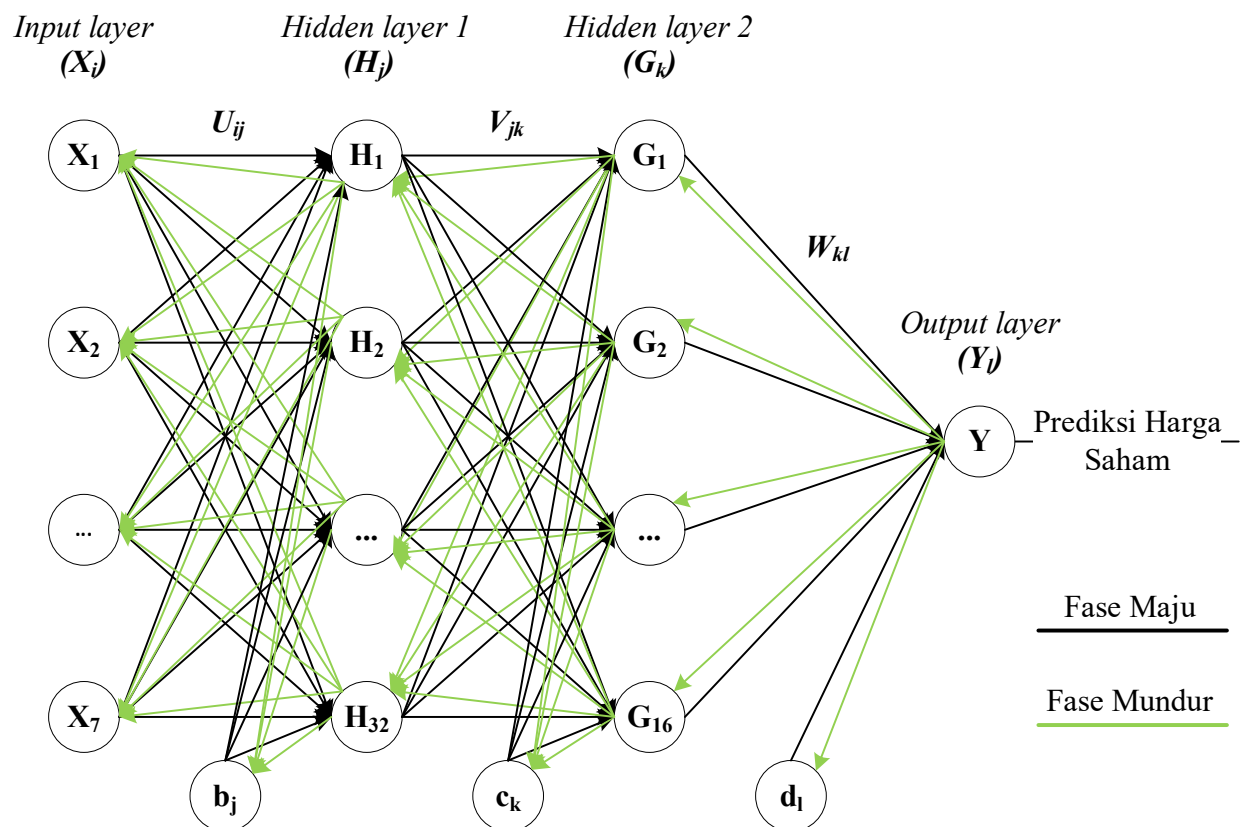
Secara konseptual, variabel intervening (variabel penghubung) berperan memediasi ikatan antara faktor penyebab dan hasilnya. Dampaknya bersifat tersirat, jadi biasanya sulit dilihat atau dihitung langsung. Faktor ini duduk di tengah-tengah variabel independen dan dependen, sehingga tidak memicu perubahan variabel dependen secara langsung, melainkan melalui mekanisme perantara.

BAB IV

MODEL ANN-BACKPROPAGATION DENGAN SENTIMEN

4.1 Desain

Konsep bagian ini memaparkan proses bertahap penulis dalam menangani permasalahan yang diteliti. Dalam penelitian ini model ANN digunakan untuk melakukan prediksi harga saham ADMR. Selanjutnya, arsitektur pada penelitian ini menggunakan algoritma *Back-propagation Neural Network* (BPNN) dengan sentimen yang terdiri dari satu (1) dan dua (2) *hidden layer* pada masing-masing eksperimen penelitian. Secara lebih detail arsitektur tersebut disajikan pada Gambar 4.1.



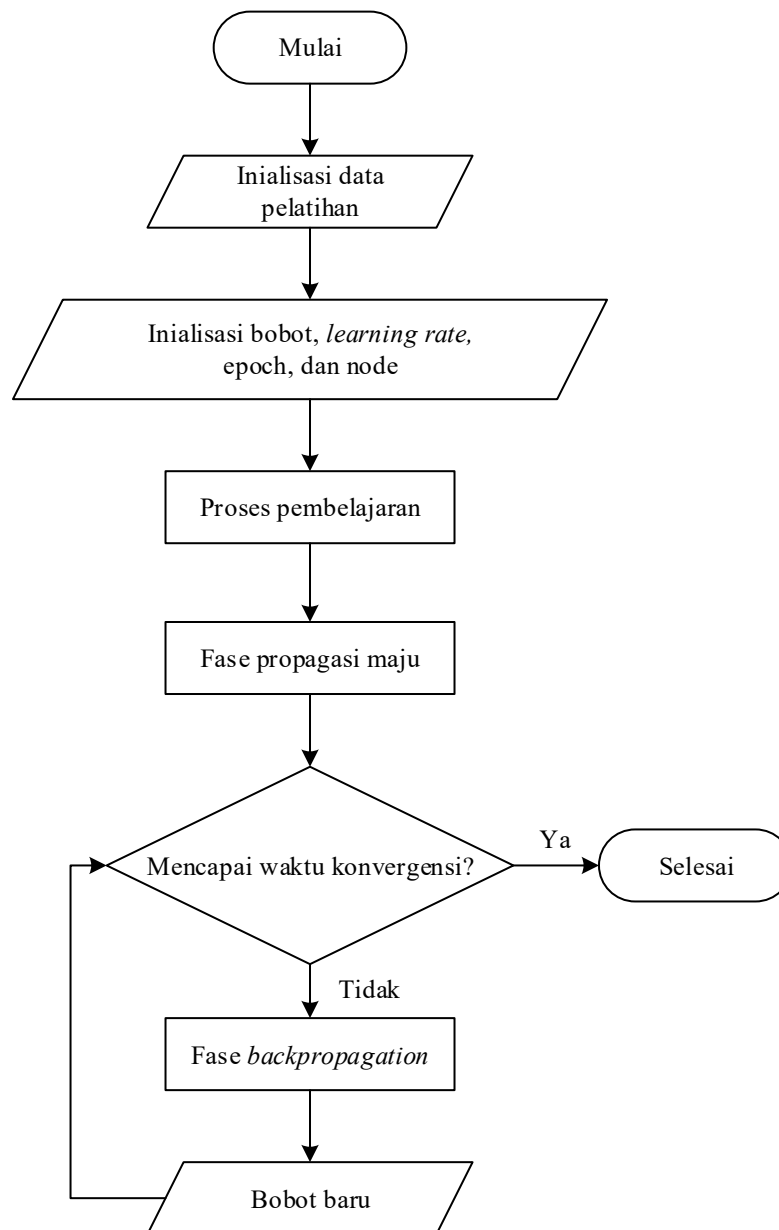
Gambar 4. 1 Arsitektur model BPNN dengan Sentimen

Desain jaringan pada skenario pertama menggunakan arsitektur dengan satu (1) *hidden layer* (7-32-1) dan dua (2) *hidden layer* (7-32-16-1) dan menggunakan model ANN dengan algoritma *backpropagation* (BPNN) berdasarkan data sentimen, dengan konfigurasi tujuh neuron input, dua hidden layer, serta satu neuron output. Back-propagation Neural Network (BPNN) termasuk dalam metode pembelajaran yang tergolong supervised learning. Data masukan (X_i) mencakup tujuh atribut yang mewakili kombinasi data historis dan sentimen pasar ADMR, yaitu Date, Open, High, Low, Close, Volume, dan Sentimen (X_1 - X_7). Seluruh input ini menjadi dasar bagi model untuk mempelajari pola harga saham sekaligus pengaruh dinamika sentimen pasar. Pada tahap berikutnya, setiap neuron input terhubung ke hidden layer pertama (H_1 - H_{32}) melalui nilai pembobotan U_{ij} , disertai nilai bias b_j . Hidden layer pertama terdiri dari 32 neuron, yang menghasilkan keluaran H_j setelah melalui fungsi aktivasi. Hasil dari lapisan tersembunyi pertama kemudian dialirkan ke lapisan tersembunyi kedua (G_1 - G_{16}) yang berisi 16 neuron melalui pembobotan V_{jk} dan bias c_k , sehingga menghasilkan output intermediate G_k . Lapisan kedua ini berfungsi memperdalam proses ekstraksi pola non-linear dari hubungan antara variabel teknikal dan sentimen.

Dalam rangka penelitian ini, proses pelatihan model dilakukan dengan membandingkan hasil prediksi output terhadap data aktual, selanjutnya menghitung selisih error yang terjadi. Selisih error tersebut dimanfaatkan sebagai acuan untuk memperbarui bobot-bobot jaringan melalui algoritma propagasi balik, sehingga model secara bertahap mendekati kondisi optimal. Dengan cara ini, model diharapkan mampu mengenali pola tersembunyi dalam data historis yang sulit dideteksi secara manual. Keunggulan BPNN adalah fleksibilitasnya dalam menyesuaikan bobot dan bias sesuai kompleksitas data, sehingga dapat memberikan hasil prediksi yang lebih adaptif (Adriyendi, 2025). Namun demikian, efektivitas model tetap sangat dipengaruhi oleh kualitas data masukan dan parameter pelatihan yang digunakan. Oleh karena itu, pengaturan arsitektur dan parameter pada skenario pertama ini menjadi tahap penting untuk sehingga mampu menghasilkan prediksi harga saham yang presisi dan konsisten.

Dalam proses pelatihannya, digunakan MSE, MAE, dan R^2 sebagai acuan untuk menghentikan iterasi sekaligus menentukan bobot optimal. Dengan kata lain, pelatihan akan berhenti ketika jaringan sudah mencapai titik konvergensi, yaitu saat error berada pada tingkat minimum yang diharapkan sehingga bobot akhir dianggap stabil (Ulama & Utami, 2016).

Pendekatan ini membuat jaringan mampu menyesuaikan bobot secara bertahap hingga mencapai performa terbaiknya. Proses pembelajaran dilakukan secara berulang dengan menyesuaikan selisih antara output yang dihasilkan jaringan dan target yang diinginkan. Dengan demikian, backpropagation berfungsi sebagai mekanisme koreksi agar model semakin akurat dalam melakukan prediksi (Fagustina, 2014). Selanjutnya, *flowchart* proses pelatihan pada skenario pertama dalam memprediksi harga saham disajikan pada Gambar 4.2.



Gambar 4. 2 Flowchart model ANN

Proses perhitungan pada skenario pertama dimulai dengan inisialisasi data input. Pada tahap ini, data yang akan digunakan dipersiapkan terlebih dahulu, biasanya melalui proses praproses seperti normalisasi agar lebih sesuai dengan kebutuhan model. Setelah data siap, langkah berikutnya adalah inisialisasi parameter model, yaitu penentuan nilai awal bobot dan bias secara acak. Penentuan parameter ini sangat penting karena akan berpengaruh terhadap laju konvergensi dan hasil pelatihan.

Tahap berikutnya melibatkan proses propagasi maju (*forward propagation*), di mana data masukan dialirkan melalui lapisan-lapisan neuron dalam jaringan. Setiap masukan dikalikan dengan bobot terkait, ditambahkan bias, kemudian diproses melalui fungsi aktivasi hingga menghasilkan output akhir. Output tersebut kemudian dibandingkan dengan nilai target aktual untuk menghitung selisih error menggunakan rumus *Mean Square Error* (MSE). Semakin rendah nilai MSE, semakin optimal performa jaringan dalam memproses keluaran sesuai target.

Setelah nilai error diperoleh, proses berlanjut pada fase propagasi balik (*backward propagation*). Pada tahap ini, error disebarkan kembali ke lapisan-lapisan sebelumnya dengan menghitung gradien turunan untuk mengetahui kontribusi bobot terhadap kesalahan yang terjadi. Informasi tersebut kemudian digunakan dalam fase perubahan bobot (*weight update*), yaitu memperbarui nilai bobot serta bias menggunakan algoritma gradient descent. Proses iteratif ini dilanjutkan secara berulang hingga jaringan mencapai konvergensi, yaitu saat error mencapai nilai minimum dan performa model dinilai optimal.

4.2 Implementasi

Lebih lanjut, arsitektur model dalam penelitian ini dikembangkan menggunakan *Visual Studio Code* dengan konfigurasi satu (1) *hidden layer* serta dua (2) *hidden layer* pada setiap eksperimen. Evaluasi optimalisasi arsitektur jaringan dilakukan berdasarkan nilai *Mean Squared Error* (MSE) dari eksperimen yang telah dirancang sebelumnya. Pada tahap pelatihan, model *Back-propagation Neural Network* (BPNN) yang mengintegrasikan variabel sentimen menerapkan berbagai parameter utama seperti jumlah neuron, fungsi aktivasi, learning rate, batas maksimum epoch, serta proporsi pembagian data *training* dan *testing*. Rincian parameter pelatihan model BPNN untuk prediksi harga saham disajikan dalam Tabel 4.1.

Tabel 4. 1 Parameter model prediksi harga saham ADMR

Parameter	Variasi Nilai yang Diuji	Alasan Pemilihan
Model jaringan	Backpropagation	Stabil dan umum digunakan untuk regresi time series
Fungsi aktivasi hidden layer	ReLU, Leaky ReLU	Mengatasi non-linearitas dan vanishing gradient
Fungsi aktivasi output layer	Linear	Sesuai untuk prediksi nilai kontinu
Optimizer	Adam, RMSprop	Adaptif terhadap data volatil dan noise
Fungsi loss	MSE, MAE, R2	MSE sensitif terhadap error besar, MAE lebih robust
Jumlah neuron input layer	7 neuron	Menyesuaikan skenario dengan dan tanpa sentimen
Jumlah hidden layer	1–2 layer	Menguji kedalaman jaringan pada data kompleks
Hidden layer pertama	32 neuron	Menangkap pola non-linier tingkat awal
Hidden layer kedua	32, 16 neuron	Memodelkan interaksi fitur yang lebih kompleks
Output layer	1 neuron	Prediksi satu nilai harga saham
Learning rate	0,0001; 0,001; 0,01	Menyesuaikan kecepatan konvergensi data fluktuatif
Epoch maksimum	200, 300	Menghindari underfitting dan overfitting
Normalisasi data	Min–Max Scaling	Menyamakan skala fitur berbeda
Skema pembagian data	80:20	Menyesuaikan ukuran data
Karakteristik data	Non-linier	Mendasari pemilihan arsitektur dan parameter
Kriteria evaluasi akhir	MSE terendah & stabil	Menentukan model terbaik

4. 3 Eksperimen

Eksperimen skenario pertama dilakukan dengan melatih model BPNN melalui pembagian data menjadi training set dan testing set dengan rasio 80%:20%, atau sekitar 565:141 data dari hasil normalisasi yang kemudian digunakan untuk pengujian pada setiap eksperimen. Selain itu, penentuan jumlah neuron per layer serta pemilihan atribut sebagai variabel target didasarkan pada tinjauan literatur yang merujuk pada temuan penelitian terdahulu (Aqila *et al.*, 2019; Bailey, 2005; Fausett, 1994; Sahi *et al.*, 2023; Thomas *et al.*, 2017). Secara rinci proses eksperimen skenario pertama temuan penelitian ini dirangkum pada Tabel 4.2

Tabel 4. 2 Eksperimen skenario pertama

Model	Arsitektur Neuron	Aktivasi Hidden	Optimizer	Learning Rate	Nama Pelatihan
BPNN + Sentimen	7-32-1	ReLU	Adam	0,001	BPNNS-A1
BPNN + Sentimen	7-32-1	ReLU	RMSprop	0,001	BPNNS-A1-R
BPNN + Sentimen	7-32-1	Leaky ReLU	Adam	0,001	BPNNS-A1-L
BPNN + Sentimen	7-32-1	ReLU	Adam	0,0001	BPNNS-A1-LR1
BPNN + Sentimen	7-32-1	ReLU	Adam	0,01	BPNNS-A1-LR3
BPNN + Sentimen	7-32-16-1	ReLU	Adam	0,001	BPNNS-A2
BPNN + Sentimen	7-32-16-1	ReLU	RMSprop	0,001	BPNNS-A2-R
BPNN + Sentimen	7-32-1	ReLU	Adam	0,001	BPNNS-B1
BPNN + Sentimen	7-32-1	Leaky ReLU	Adam	0,001	BPNNS-B1-L
BPNN + Sentimen	7-32-16-1	ReLU	Adam	0,001	BPNNS-B2
BPNN + Sentimen	7-32-1	ReLU	Adam	0,001	BPNNS-C1
BPNN + Sentimen	7-32-16-1	ReLU	Adam	0,001	BPNNS-C2
BPNN + Sentimen	7-32-1	ReLU	Adam	0,001	BPNNS-D1
BPNN + Sentimen	7-32-16-1	ReLU	Adam	0,001	BPNNS-D2

Untuk mengevaluasi pengaruh penambahan informasi sentimen terhadap kinerja model dalam memprediksi harga saham ADMR, penelitian ini merancang serangkaian eksperimen pada skenario pertama seperti yang ditampilkan pada Tabel 4.2. Pada skenario ini, seluruh eksperimen menggunakan model Backpropagation Neural Network (BPNN) yang diperkaya dengan variabel sentimen, sehingga jumlah masukan variabel yang dipakai mencapai tujuh, yaitu Date, Open, High, Low, Close, Volume, dan Sentimen. Eksperimen awal menerapkan arsitektur satu lapisan tersembunyi (7–32–1) dengan fungsi aktivasi ReLU, optimizer Adam, dan learning rate sebesar 0,001, yang diberi kode BPNNS-A1. Untuk melihat pengaruh pemilihan optimizer, konfigurasi yang sama kemudian diuji menggunakan RMSprop dan dikodekan sebagai BPNNS-A1-R. Selain itu, pengaruh variasi fungsi aktivasi dianalisis dengan mengganti ReLU menjadi Leaky ReLU, yang direpresentasikan oleh eksperimen BPNNS-A1-L.

Penelitian ini juga mengeksplorasi sensitivitas model terhadap perubahan learning rate. Dua variasi tambahan digunakan, yaitu learning rate 0,0001 dan 0,01, yang masing-masing diberi kode BPNNS-A1-LR1 dan BPNNS-A1-LR3, sementara konfigurasi parameter lainnya tetap dipertahankan. Untuk menguji pengaruh kompleksitas arsitektur jaringan, eksperimen selanjutnya menggunakan arsitektur dua hidden layer (7–32–16–1), yang dikodekan sebagai BPNNS-A2, serta variasinya dengan optimizer RMSprop yang diberi kode BPNNS-A2-R. Pendekatan eksperimen yang sama kemudian diterapkan pada target prediksi yang berbeda. Ketika atribut High dijadikan sebagai variabel target, eksperimen menggunakan arsitektur satu hidden layer dan dua hidden layer masing-masing diberi kode BPNNS-B1 dan BPNNS-B2. Untuk atribut Low, konfigurasi yang digunakan direpresentasikan oleh BPNNS-C1 dan BPNNS-C2, sedangkan ketika atribut Close dijadikan target prediksi, eksperimen tersebut masing-masing dikodekan sebagai BPNNS-D1 dan BPNNS-D2.

4.3.1 Ekperimen BPNNS-A1


Berdasarkan konfigurasi eksperimen pada Tabel 4.2, eksperimen BPNNS-A1 merupakan eksperimen awal pada skenario pertama yang menggunakan model BPNN dengan data sentimen, arsitektur satu hidden layer (7–32–1), fungsi aktivasi ReLU, optimizer Adam, dan learning rate sebesar 0,001. Dalam eksperimen ini, atribut Open ditetapkan sebagai variabel target, sedangkan

atribut lainnya berfungsi sebagai variabel input. Pelatihan model dilakukan dengan proporsi pembagian data 80% untuk training set dan 20% untuk testing set. Hasil pelatihan model pada eksperimen BPNN-A1 dirangkum dalam Tabel 4.3, yang memuat informasi mengenai jumlah epoch, durasi konvergensi, nilai training loss, serta validation loss.

Tabel 4. 3 Proses eksperimen BPNNS-A1


Epoch	Waktu konvergensi	Training loss	Validation loss
1	20ms / step	0,176739	0,009343
2	3ms / step	0,004318	0,001972
3	2ms / step	0,001559	0,002289
4	3ms / step	0,001092	0,001216
5	3ms / step	0,000902	0,000851
6	3ms / step	0,000773	0,000682
7	2ms / step	0,000678	0,000634
8	2ms / step	0,000608	0,000653
9	3ms / step	0,000555	0,000759
10	2ms / step	0,000509	0,000897
...
125	4ms / step	3,145830	0,000367

Tabel 4.3 mengindikasikan bahwa pelatihan pada eksperimen BPNN-A1 berhasil dikonvergensi pada iterasi ke-125 dengan waktu rata-rata 4ms / step, training loss sebesar 3,145830, serta validation loss mencapai 0,000367. Visualisasi hasil proses pelatihan ini bisa diamati dalam Gambar 4.3.



Gambar 4. 3 Grafik training loss eksperimen BPNNS-A1

Dari Tabel 4.3 terlihat bahwa pelatihan pada eksperimen BPNN-A1 berhenti pada epoch ke-125 dengan durasi konvergensi sekitar 4 ms / step. Di akhir proses, model mencatat training loss sebesar 3,145830 dan validation loss 0,000367. Nilai validation loss yang sangat rendah mengindikasikan kemampuan generalisasi model yang baik terhadap data pengujian. Perkembangan training loss dan validation loss divisualisasikan pada Gambar 4.3, yang memperlihatkan tren penurunan loss secara stabil seiring peningkatan epoch, menandakan konvergensi pembelajaran yang optimal.



Gambar 4. 4 Perbandingan data aktual dan data prediksi harga saham ADMR pada eksperimen BPNN-A1


4.3.2 Ekperimen BPNN-A1-R

Berdasarkan konfigurasi eksperimen pada Tabel 4.2, eksperimen BPNN-A1-R merupakan variasi dari arsitektur satu hidden layer (7–32–1) pada skenario pertama yang menggunakan model BPNN dengan data sentimen, fungsi aktivasi ReLU, optimizer RMSprop, dan learning rate sebesar 0,001. Pada eksperimen ini, atribut Open ditetapkan sebagai variabel target, sedangkan atribut lainnya digunakan sebagai variabel input. Pelatihan model dilakukan dengan proporsi data 80% untuk training set dan 20% untuk testing set. Hasil pelatihan pada eksperimen BPNN-A1-R dirangkum dalam Tabel 4.4, yang mencakup informasi jumlah epoch, durasi konvergensi, training loss, serta validation loss.

Tabel 4. 4 Proses eksperimen BPNN- A1-R


Epoch	Waktu Konvergensi	Training Loss	Validation Loss
1	22 ms / step	0,176739	0,009343
2	3 ms / step	0,004318	0,001972
3	3 ms / step	0,001559	0,002289
4	3 ms / step	0,001092	0,001216
5	2 ms / step	0,000902	0,000851
6	3 ms / step	0,000773	0,000682
7	3 ms / step	0,000678	0,000634
8	3 ms / step	0,000608	0,000653
9	3 ms / step	0,000555	0,000759
10	3 ms / step	0,000509	0,000897
...
108	3 ms / step	0,000418	0,000436

Tabel 4.4 mengisyaratkan pelatihan pada eksperimen BPNN-A1-R dikonvergensi pada epoch ke-108 dengan waktu rata-rata 3 ms / step. Di akhir proses, model mencatat training loss sebesar 0,000418 dan validation loss 0,000436. Nilai loss yang rendah dan saling berdekatan mencerminkan kemampuan model dalam melakukan pembelajaran efektif serta generalisasi yang baik. Visualisasi training loss beserta validation loss tersaji dalam Gambar 4.5, yang menampilkan tren penurunan loss secara stabil seiring peningkatan epoch, mengonfirmasi konvergensi pelatihan yang optimal.

**Gambar 4. 5 Grafik training loss eksperimen BPNN-A1-R**

Lebih lanjut, perbandingan antara data aktual dengan hasil prediksi harga saham ADMR pada eksperimen BPNN-A1-R divisualisasikan pada Gambar 4.6. Grafik tersebut menunjukkan bahwa pola pergerakan data prediksi memiliki kemiripan yang cukup konsisten dengan data aktual.

Kedua kurva cenderung bergerak sejajar dan mengikuti tren yang sama pada sebagian besar periode pengamatan. Meskipun masih terdapat perbedaan nilai pada beberapa titik tertentu, kesamaan pola pergerakan tersebut mencerminkan kemampuan model dalam merepresentasikan tren dan arah pergerakan harga saham secara efektif. Secara keseluruhan, performa model BPNN-A1-R dalam meramalkan harga saham ADMR dapat diklasifikasikan baik, karena berhasil mengidentifikasi pola fluktuasi harga dengan tingkat akurasi yang memadai.



Gambar 4. 6 Perbandingan data aktual dan data prediksi harga saham ADMR pada eksperimen BPNN-A1-R


4.3.3 Ekperimen BPNN-A1-L

Berdasarkan rancangan eksperimen pada Tabel 4.2, eksperimen BPNN-A1-L mewakili variasi skenario pertama dengan model BPNN yang diperkaya data sentimen, arsitektur satu hidden layer (7–32–1), fungsi aktivasi Leaky ReLU, optimizer Adam, serta learning rate 0,001. Atribut Open ditetapkan sebagai target variable, sementara atribut lainnya berperan sebagai input variable. Pelatihan model menggunakan rasio 80% data training dan 20% data testing. Hasil pelatihan eksperimen BPNN-A1-L dirangkum dalam Tabel 4.5, yang memuat data epoch, waktu konvergensi, training loss, dan validation loss.

Tabel 4. 5 Proses pelatihan eksperimen BPNN-A1-L


Epoch	Waktu Konvergensi	Training Loss	Validation Loss
1	22 ms / step	0,176739	0,009343
2	3 ms / step	0,004318	0,001972
3	3 ms / step	0,001559	0,002289
4	3 ms / step	0,001092	0,001216
5	2 ms / step	0,000902	0,000851
6	3 ms / step	0,000773	0,000682
7	3 ms / step	0,000678	0,000634
8	3 ms / step	0,000608	0,000653
9	3 ms / step	0,000555	0,000759
10	3 ms / step	0,000509	0,000897
...
174	3 ms / step	0,000429	0,000441

Dari Tabel 4.5 terlihat bahwa pelatihan pada eksperimen BPNN-A1-L dikonvergensi pada epoch ke-174 dengan waktu rata-rata 3 ms / step. Di akhir proses, model mencatat training loss sebesar 0,000429 dan validation loss 0,000441. Kedekatan kedua nilai loss tersebut mencerminkan stabilitas pembelajaran model serta kemampuan generalisasi yang baik terhadap data pengujian. Visualisasi perkembangan loss pelatihan serta validasi tersaji di Gambar 4.7, yang menampilkan tren penurunan loss secara stabil hingga mencapai konvergensi.

**Gambar 4. 7 Grafik training loss eksperimen BPNN-A1-L**

Selanjutnya, perbandingan antara data aktual dan data hasil prediksi harga saham ADMR pada eksperimen BPNN-A1-L disajikan pada Gambar 4.8. Grafik tersebut menunjukkan bahwa pola pergerakan data prediksi memiliki kemiripan yang cukup konsisten dengan data aktual. Kedua kurva bergerak dengan tren yang hampir sejajar pada sebagian besar periode pengamatan.

Meskipun masih terdapat perbedaan nilai pada beberapa titik tertentu, kesamaan pola tersebut mengindikasikan bahwa model mampu menangkap arah dan tren pergerakan harga dengan cukup baik. Secara keseluruhan, hasil ini menunjukkan bahwa performa model BPNNS-A1-L dalam memprediksi harga saham ADMR dapat dikategorikan baik, karena berhasil merepresentasikan pola pergerakan harga secara akurat.



Gambar 4. 8 Komparasi data sebenarnya dan data prediksi harga saham ADMR pada eksperimen BPNNS-A1-L


4.3.4 Ekperimen BPNNS-A1-LR1

Berdasarkan konfigurasi eksperimen pada Tabel 4.2, eksperimen BPNNS-A1-LR1 merupakan variasi pada skenario pertama yang menggunakan model BPNN dengan penambahan data sentimen, arsitektur satu hidden layer (7–32–1), fungsi aktivasi ReLU, optimizer Adam, serta learning rate yang diperkecil menjadi 0,0001. Pada eksperimen ini, atribut Open digunakan sebagai variabel target, sedangkan atribut lainnya berperan sebagai variabel input. Proses pelatihan dilakukan dengan rasio pembagian data 80% data latih dan 20% data uji. Hasil proses pelatihan model pada eksperimen BPNNS-A1-LR1 disajikan pada Tabel 4.6, yang memuat informasi mengenai jumlah epoch, waktu konvergensi, nilai training loss, dan validation loss.

Tabel 4. 6 Proses eksperimen BPNN-A1-LR1


Epoch	Waktu Konvergensi	Training Loss	Validation Loss
1	22 ms / step	0,176739	0,009343
2	3 ms / step	0,004318	0,001972
3	3 ms / step	0,001559	0,002289
4	3 ms / step	0,001092	0,001216
5	2 ms / step	0,000902	0,000851
6	3 ms / step	0,000773	0,000682
7	3 ms / step	0,000678	0,000634
8	3 ms / step	0,000608	0,000653
9	3 ms / step	0,000555	0,000759
10	3 ms / step	0,000509	0,000897
...
125	2 ms / step	0,000218	0,000231

Merujuk pada Tabel 4.6, pelatihan pada eksperimen BPNN-A1-LR1 berhenti pada epoch ke-125 dengan durasi konvergensi selama 2 ms / step. Di akhir proses, model mencatat training loss sebesar 0,000218 dan validation loss 0,000231. Nilai loss yang rendah dengan selisih minimal antara training dan validation loss mengindikasikan stabilitas pembelajaran serta kemampuan generalisasi yang optimal. Visualisasi perkembangan loss pelatihan serta validasi tersaji di Gambar 4.9, yang memperlihatkan tren penurunan loss secara konsisten hingga konvergensi tercapai.

**Gambar 4. 9 Grafik training loss eksperimen BPNN-A1-LR1**

Lebih lanjut, perbandingan antara data aktual dengan hasil prediksi harga saham ADMR pada eksperimen BPNN-A1-LR1 divisualisasikan pada Gambar 4.10. Grafik tersebut menunjukkan bahwa pola pergerakan data prediksi memiliki kemiripan yang cukup konsisten

dengan data aktual. Kedua kurva bergerak hampir sejajar dan mengikuti tren yang sama pada sebagian besar periode pengamatan. Meskipun masih terdapat beberapa selisih nilai pada titik tertentu, kesamaan pola tersebut mencerminkan kemampuan model dalam merepresentasikan tren dan arah pergerakan harga secara efektif. Secara keseluruhan, performa model BPNN-A1-LR1 dalam meramalkan harga saham ADMR dapat diklasifikasikan baik, serta mengonfirmasi bahwa learning rate yang lebih rendah menghasilkan proses pelatihan yang lebih stabil.



Gambar 4. 10 Perbandingan data aktual dan data prediksi harga saham ADMR pada eksperimen BPNN-A1-LR1


4.3.5 Ekperimen BPNN-A1-LR3

Berdasarkan konfigurasi eksperimen pada Tabel 4.2, eksperimen BPNN-A1-LR3 merupakan salah satu variasi pada skenario pertama yang menggunakan model BPNN dengan penambahan data sentimen, arsitektur satu hidden layer (7–32–1), fungsi aktivasi ReLU, optimizer Adam, serta learning rate yang diperbesar menjadi 0,01. Pada eksperimen ini, atribut Open ditetapkan sebagai variabel target, sedangkan atribut lainnya digunakan sebagai variabel input. Proses pelatihan dilakukan dengan proporsi pembagian data 80% untuk pelatihan dan 20% untuk pengujian. Hasil proses pelatihan model pada eksperimen BPNN-A1-LR3 disajikan pada Tabel 4.7, yang memuat informasi mengenai jumlah epoch, waktu konvergensi, nilai training loss, dan validation loss.


Tabel 4. 7 Proses pelatihan eksperimen BPNN-A1-LR3

Epoch	Waktu Konvergensi	Training Loss	Validation Loss
1	22 ms / step	0,176739	0,009343
2	3 ms / step	0,004318	0,001972
3	3 ms / step	0,001559	0,002289
4	3 ms / step	0,001092	0,001216
5	2 ms / step	0,000902	0,000851
6	3 ms / step	0,000773	0,000682
7	3 ms / step	0,000678	0,000634
8	3 ms / step	0,000608	0,000653
9	3 ms / step	0,000555	0,000759
10	3 ms / step	0,000509	0,000897
...
125	2 ms / step	0,000487	0,000521

Tabel 4.7 menyajikan hasil pelatihan, yang menunjukkan pada eksperimen BPNN-A1-LR3 terhenti pada epoch ke-125 dengan kecepatan konvergensi sekitar 2 ms / step. Di akhir pelatihan, model mencapai training loss sebesar 0,000487 dan validation loss 0,000521. Kesenjangan validation loss yang lebih tinggi dibandingkan eksperimen dengan learning rate lebih rendah mengindikasikan bahwa learning rate terlalu besar mengganggu kestabilan pembelajaran model, sebagaimana divisualisasikan pada kurva loss di Gambar 4.11. Grafik tersebut memperlihatkan fluktuasi loss yang relatif lebih besar sebelum mencapai kondisi konvergen, yang mengindikasikan proses pembelajaran yang kurang stabil dibandingkan eksperimen dengan learning rate yang lebih kecil.

**Gambar 4. 11 Grafik training loss eksperimen BPNN-A1-LR3**

Selanjutnya, perbandingan antara nilai aktual dan prediksi harga saham ADMR pada eksperimen BPNN-A1-LR3 ditampilkan pada Gambar 4.12. Grafik tersebut mengindikasikan bahwa pola tren prediksi tetap selaras dengan data riil, meskipun deviasi lebih nyata pada beberapa titik observasi. Secara keseluruhan, kinerja model BPNN-A1-LR3 dalam meramalkan harga saham ADMR tergolong cukup baik, tetapi kurang optimal dibandingkan konfigurasi learning rate lebih rendah, sehingga menekankan krusialnya pemilihan learning rate untuk kestabilan dan presisi model.



Gambar 4. 12 Perbandingan data aktual dan data prediksi harga saham ADMR pada eksperimen BPNN-A1-LR3


4.3.6 Ekperimen BPNN-A2

Berdasarkan konfigurasi eksperimen pada Tabel 4.2, eksperimen BPNN-A2 merupakan pengembangan dari skenario pertama dengan menggunakan model BPNN berbasis sentimen yang menerapkan dua hidden layer dengan arsitektur neuron 7–32–16–1. Fungsi aktivasi yang digunakan pada hidden layer adalah ReLU, optimizer Adam, serta learning rate sebesar 0,001. Pada eksperimen ini, data dibagi dengan rasio 80% sebagai data latih dan 20% sebagai data uji, sedangkan atribut Low digunakan sebagai variabel target. Hasil proses pelatihan model pada eksperimen BPNN-A2 ditampilkan pada Tabel 4.8, yang menyajikan informasi jumlah epoch, waktu konvergensi, nilai training loss, dan validation loss selama proses pelatihan.

Tabel 4. 8 Proses pelatihan eksperimen BPNNS-A2


Epoch	Waktu Konvergensi	Training Loss	Validation Loss
1	22 ms / step	0,176739	0,009343
2	3 ms / step	0,004318	0,001972
3	3 ms / step	0,001559	0,002289
4	3 ms / step	0,001092	0,001216
5	2 ms / step	0,000902	0,000851
6	3 ms / step	0,000773	0,000682
7	3 ms / step	0,000678	0,000634
8	3 ms / step	0,000608	0,000653
9	3 ms / step	0,000555	0,000759
10	3 ms / step	0,000509	0,000897
...
70	3 ms / step	0,000119	0,000123

Berdasarkan Tabel 4.8, proses pelatihan pada eksperimen BPNNS-A2 mencapai kondisi konvergen pada epoch ke-70 dengan waktu komputasi sekitar 3 ms / step. Pada titik tersebut, diperoleh angka training loss sebesar 0,000119 dan validation loss 0,000123, mencerminkan kemampuan pembelajaran pola data yang optimal dan stabil. Penurunan loss secara konsisten menandakan bahwa penambahan satu hidden layer berhasil meningkatkan kapasitas model untuk mengungkap kompleksitas data. Kurva perkembangan training dan validation loss pada Gambar 4.13 menggambarkan tren penurunan yang lancar hingga konvergensi, tanpa fluktuasi mencolok.

**Gambar 4. 13 Grafik training loss eksperimen BPNNS-A2**

Selanjutnya, Perbandingan antara data aktual dan hasil prediksi harga saham ADMR pada eksperimen BPNNS-A2 divisualisasikan pada Gambar 4.14. Grafik tersebut menunjukkan bahwa pola pergerakan data prediksi memiliki kemiripan yang cukup konsisten dengan data aktual. Kedua

grafik bergerak dengan tren yang hampir sejajar pada setiap periode pengamatan, meskipun masih terdapat beberapa perbedaan nilai pada titik-titik tertentu. Secara keseluruhan, kesesuaian pola antara data aktual dan data prediksi menegaskan bahwa performa model BPNNS-A2 dalam memprediksi harga saham ADMR tergolong baik. Temuan ini mengonfirmasi bahwa arsitektur dua hidden layer berkontribusi positif terhadap kapabilitas model dalam mengikuti arah dan dinamika fluktuasi harga saham.



Gambar 4. 14 Komparasi data sebenarnya dan data prediksi harga saham ADMR pada eksperimen BPNNS-A2

4.3.7 Ekperimen BPNNS-A2-R

Berdasarkan konfigurasi eksperimen pada Tabel 4.2, eksperimen BPNNS-A2-R merupakan bagian dari skenario pertama yang menggunakan model BPNN berbasis sentimen dengan dua hidden layer dan arsitektur neuron 7–32–16–1. Pada eksperimen ini digunakan fungsi aktivasi ReLU pada hidden layer, optimizer RMSprop, serta learning rate sebesar 0,001. Pembagian dataset menggunakan rasio 80%:20% untuk *training set* dan *test set*, sedangkan atribut Close digunakan sebagai variabel target dalam prediksi harga saham ADMR. Hasil proses pelatihan pada eksperimen BPNNS-A2-R disajikan pada Tabel 4.9, yang menunjukkan perkembangan evolusi training loss dan validation loss tiap epoch dalam proses training.

Tabel 4. 9 Proses pelatihan eksperimen BPNNS-A2-R


Epoch	Waktu Konvergensi	Training Loss	Validation Loss
1	20 ms / step	0,176739	0,009343
2	3 ms / step	0,004318	0,001972
3	2 ms / step	0,001559	0,002289
4	3 ms / step	0,001092	0,001216
5	3 ms / step	0,000902	0,000851
6	3 ms / step	0,000773	0,000682
7	2 ms / step	0,000678	0,000634
8	2 ms / step	0,000608	0,000653
9	3 ms / step	0,000555	0,000759
10	2 ms / step	0,000509	0,000897
...
63	2 ms / step	3,09E-05	0,00046

Berdasarkan Tabel 4.9, proses pelatihan pada eksperimen BPNNS-A2-R mencapai kondisi konvergen pada epoch ke-63 dengan waktu komputasi sekitar 2 ms / step. Pada titik tersebut, diperoleh nilai training loss sebesar 0,0000309 dan validation loss sebesar 0,000460. Nilai loss yang relatif kecil serta perbedaan yang tidak signifikan antara training loss dan validation loss mengindikasikan kemampuan generalisasi model yang baik terhadap data pengujian. Kurva evolusi training loss serta validation loss selama pelatihan divisualisasikan pada Gambar 4.15, yang menggambarkan pola penurunan stabil hingga konvergensi, yang menandakan bahwa proses pembelajaran berlangsung secara efektif.

**Gambar 4. 15 Grafik training loss eksperimen BPNNS-A2-R**

Selanjutnya, hasil perbandingan antara data aktual dan data prediksi harga saham ADMR pada eksperimen BPNNS-A2-R ditampilkan pada Gambar 4.16. Grafik tersebut menunjukkan

adanya kemiripan pola yang cukup konsisten antara data aktual dan data hasil prediksi. Kedua grafik bergerak dengan tren yang hampir sejajar pada setiap periode pengamatan, meskipun masih terdapat beberapa selisih nilai pada titik-titik tertentu. Secara keseluruhan, kesesuaian pola pergerakan antara data aktual dan data prediksi menunjukkan bahwa performa model BPNN-A2-R dalam memprediksi harga saham ADMR dapat dikategorikan baik. Hal ini mengindikasikan bahwa penggunaan optimizer RMSprop pada arsitektur dua hidden layer mampu meningkatkan stabilitas proses pelatihan serta ketepatan model dalam menangkap tren pergerakan harga saham.



Gambar 4. 16 Perbandingan data prediksi dan aktual harga saham ADMR BPNN-D1


4.3.8 Ekperimen BPNN-B1

Berdasarkan konfigurasi eksperimen yang disajikan pada Tabel 4.2, eksperimen BPNN-B1 merupakan bagian dari skenario pertama yang menggunakan model BPNN berbasis sentimen dengan satu (1) hidden layer dan arsitektur neuron 7–32–1. Pada eksperimen ini diterapkan fungsi aktivasi ReLU pada hidden layer, optimizer Adam, serta learning rate sebesar 0,001. Proses pelatihan dilakukan dengan rasio pembagian dataset 80%:20% untuk *training set* dan *test set*, sedangkan atribut Close digunakan sebagai variabel target dalam prediksi harga saham ADMR. Hasil proses pelatihan pada eksperimen BPNN-B1 ditunjukkan pada Tabel 4.10, yang menggambarkan perkembangan nilai training loss dan validation loss pada setiap epoch selama proses pelatihan.

Tabel 4. 10 Proses pelatihan eksperimen BPNNS-B1


Epoch	Waktu Konvergensi	Training Loss	Validation Loss
1	21 ms / step	0,006454	0,003487
2	3 ms / step	0,001665	0,003375
3	2 ms / step	0,000927	0,002992
4	3 ms / step	0,000661	0,002594
5	2 ms / step	0,00055	0,002098
6	2 ms / step	0,000487	0,001674
7	2 ms / step	0,000439	0,001297
8	2 ms / step	0,000395	0,001029
9	2 ms / step	0,000362	0,000908
10	3 ms / step	0,000332	0,000865
...
98	2 ms / step	0,000301	0,000458

Berdasarkan Tabel 4.10, proses pelatihan pada eksperimen BPNNS-B1 mencapai kondisi konvergen pada epoch ke-98 dengan waktu komputasi sekitar 2 ms / step. Pada kondisi tersebut diperoleh Nilai training loss diperoleh sebesar 0,000301 dan validation loss sebesar 0,000458. Perbedaan keduanya yang tidak terlalu besar mengindikasikan bahwa performa model pada data validasi masih sejalan dengan performa pada data pelatihan, sehingga kemampuan generalisasi dapat dikatakan memadai. Kurva perkembangan training loss dan validation loss sepanjang epoch pelatihan disajikan pada bagian ini divisualisasikan pada Gambar 4.17, yang menampilkan tren penurunan stabil menuju konvergensi.

**Gambar 4. 17 Nilai training loss eksperimen BPNNS-B1**

Selanjutnya, visualisasi kesesuaian antara nilai harga saham aktual dan prediksi ADMR pada eksperimen BPNNS-B1 disajikan pada Gambar 4.18. Grafik tersebut menunjukkan adanya

kemiripan pola yang cukup konsisten antara nilai aktual dengan hasil prediksi. Kedua grafik bergerak dengan arah tren yang hampir sejajar pada setiap periode pengamatan, meskipun masih terdapat beberapa selisih nilai pada titik-titik tertentu. Secara keseluruhan, kesesuaian pola pergerakan antara data aktual dan data prediksi menunjukkan bahwa performa model BPNNS-B1 dalam memprediksi harga saham ADMR dapat dikategorikan baik. Hal ini menegaskan bahwa penggunaan arsitektur satu hidden layer dengan optimizer Adam mampu menangkap pola dan tren pergerakan harga saham secara efektif.



Gambar 4. 18 Perbandingan data prediksi dan aktual harga saham ADMR BPNNS-B1


4.3.9 Ekperimen BPNNS-B1-L

Berdasarkan skenario eksperimen yang ditunjukkan pada Tabel 4.2, eksperimen BPNNS-B1-L merupakan pengembangan model BPNN berbasis sentimen yang menggunakan satu (1) hidden layer dengan arsitektur neuron 7–32–1. Perbedaan utama eksperimen ini dibandingkan BPNNS-B1 terletak pada penggunaan fungsi aktivasi Leaky ReLU pada hidden layer, sementara optimizer yang digunakan tetap Adam dengan learning rate sebesar 0,001. Proses pelatihan dilakukan menggunakan proporsi data 80% untuk pelatihan dan 20% untuk pengujian, dengan atribut Close sebagai variabel target dalam prediksi harga saham ADMR. Hasil proses pelatihan pada eksperimen BPNNS-B1-L disajikan pada Tabel 4.11, yang memperlihatkan perkembangan evolusi training loss serta validation loss pada setiap epoch dalam tahap learning.


Tabel 4. 11 Proses eksperimen BPNNS-B1-L

Epoch	Waktu konvergensi	Training loss	Validation loss
1	21ms / step	0,006454	0,003487
2	3ms / step	0,001665	0,003375
3	2ms / step	0,000927	0,002992
4	3ms / step	0,000661	0,002594
5	2ms / step	0,00055	0,002098
6	2ms / step	0,000487	0,001674
7	2ms / step	0,000439	0,001297
8	2ms / step	0,000395	0,001029
9	2ms / step	0,000362	0,000908
10	3ms / step	0,000332	0,000865
...
61	2ms / step	3,122860	0,00046

Berdasarkan Tabel 4.11, proses pelatihan pada eksperimen BPNNS-B1-L mencapai kondisi konvergensi pada epoch ke-61 dengan waktu komputasi sekitar 2 ms / step. Pada kondisi tersebut diperoleh model mencapai training loss sebesar 0,000312 dan validation loss 0,000460. Kesenjangan kecil antara kedua loss tersebut serta nilai validation yang rendah mengindikasikan kemampuan generalisasi yang optimal tanpa indikasi overfitting signifikan. Kurva penurunan training loss dan validation loss selama pelatihan eksperimen BPNN-B1-L divisualisasikan dalam Gambar 4.19.

**Gambar 4. 19 Nilai loss pelatihan eksperimen BPNNS-B1-L**

Selanjutnya, Gambar 4.20 menyajikan komparasi antara data sebenarnya dan data prediksi harga saham ADMR yang dihasilkan dari model BPNNS-B1-L. Grafik tersebut menunjukkan bahwa pola pergerakan harga hasil prediksi memiliki kemiripan yang cukup konsisten dengan data aktual. Kedua grafik bergerak mengikuti arah tren yang hampir sejajar pada setiap periode pengamatan, meskipun masih terdapat beberapa selisih nilai pada titik-titik tertentu. Secara keseluruhan, kesesuaian pola antara data aktual dan data prediksi menegaskan bahwa performa model BPNNS-B1-L dalam memprediksi harga saham ADMR dapat dikategorikan baik. Penggunaan fungsi aktivasi Leaky ReLU pada hidden layer terbukti mampu menjaga stabilitas proses pelatihan serta membantu model dalam menangkap pola pergerakan harga saham secara efektif.



Gambar 4. 20 Perbandingan data prediksi dan aktual harga saham ADMR BPNNS-B1-L

4.3.10 Ekperimen BPNNS-B2


Berdasarkan konfigurasi eksperimen yang ditampilkan pada Tabel 4.2, eksperimen BPNNS-B2 merupakan model Backpropagation Neural Network (BPNN) berbasis sentimen yang menggunakan dua (2) hidden layer dengan arsitektur neuron 7–32–16–1. Model ini menerapkan fungsi aktivasi ReLU di seluruh hidden layer, optimizer Adam, serta learning rate 0,001. Proses pelatihan dilakukan dengan rasio data 80% sebagai data latih dan 20% sebagai data uji, dengan atribut Close sebagai variabel target dalam prediksi harga saham ADMR. Hasil proses pelatihan

pada eksperimen BPNNS-B2 ditunjukkan pada Tabel 4.12, yang menggambarkan perubahan evolusi nilai training loss dan validation loss pada setiap epoch selama proses pembelajaran.

Tabel 4. 12 Proses eksperimen BPNNS-B2


Epoch	Waktu Konvergensi	Training Loss	Validation Loss
1	21 ms / step	0,006454	0,003487
2	3 ms / step	0,001665	0,003375
3	2 ms / step	0,000927	0,002992
4	3 ms / step	0,000661	0,002594
5	2 ms / step	0,00055	0,002098
6	2 ms / step	0,000487	0,001674
7	2 ms / step	0,000439	0,001297
8	2 ms / step	0,000395	0,001029
9	2 ms / step	0,000362	0,000908
10	3 ms / step	0,000332	0,000865
...
79	2 ms / step	0,000315	0,000462

Berdasarkan Tabel 4.12, proses pelatihan pada eksperimen BPNNS-B2 mencapai kondisi konvergensi pada epoch ke-79 dengan waktu komputasi sekitar 2 ms / step. Pada titik tersebut diperoleh model mencapai training loss sebesar 0,000315 dan validation loss 0,000462. Kedekatan nilai kedua loss tersebut mengindikasikan stabilitas pembelajaran yang baik serta kemampuan generalisasi data yang optimal. Kurva penurunan training loss dan validation loss selama pelatihan eksperimen BPNN-B2 divisualisasikan pada Gambar 4.21.



Gambar 4. 21 Nilai training loss eksperimen BPNNS-B2

Selanjutnya, Gambar 4.22 menyajikan grafik komparasi antara data sebenarnya dan data prediksi harga saham ADMR yang dihasilkan dari model BPNNS-B2. Hasil visualisasi menunjukkan bahwa pola pergerakan harga hasil prediksi memiliki kemiripan yang cukup konsisten dengan data aktual. Kedua grafik bergerak mengikuti arah tren yang hampir sejajar pada setiap periode pengamatan, meskipun masih terdapat perbedaan nilai pada beberapa titik tertentu. Secara keseluruhan, kesesuaian pola antara data aktual dan data prediksi menegaskan bahwa performa model BPNNS-B2 dalam memprediksi harga saham ADMR dapat dikategorikan baik. Penambahan satu hidden layer pada arsitektur jaringan terbukti mampu meningkatkan kemampuan model dalam menangkap pola nonlinier pada data harga saham secara lebih efektif.



Gambar 4. 22 Perbandingan data prediksi dan aktual harga saham ADMR BPNNS-B2

4.3.11 Ekperimen BPNNS-C1


Berdasarkan konfigurasi eksperimen pada Tabel 4.2, eksperimen BPNNS-C1 merupakan model Backpropagation Neural Network (BPNN) dengan penambahan data sentimen yang menggunakan satu (1) hidden layer dengan arsitektur neuron 7–32–1. Model ini menerapkan fungsi aktivasi ReLU pada hidden layer, optimizer Adam, dan learning rate 0,001. Pelatihan dilakukan dengan proporsi data 80% untuk training set dan 20% untuk test set, dengan atribut Low sebagai variabel target dalam prediksi harga saham ADMR. Hasil proses pelatihan pada eksperimen BPNNS-C1 ditampilkan pada Tabel 4.13, yang menunjukkan perkembangan

perkembangan nilai training loss dan validation loss tiap epoch selama proses pembelajaran berlangsung.

Tabel 4. 13 Proses eksperimen BPNNS-C1


Epoch	Waktu konvergensi	Training loss	Validation loss
1	21ms / step	0,006454	0,003487
2	3ms / step	0,001665	0,003375
3	2ms / step	0,000927	0,002992
4	3ms / step	0,000661	0,002594
5	2ms / step	0,00055	0,002098
6	2ms / step	0,000487	0,001674
7	2ms / step	0,000439	0,001297
8	2ms / step	0,000395	0,001029
9	2ms / step	0,000362	0,000908
10	3ms / step	0,000332	0,000865
...
61	2ms / step	3,122860	0,00046

Berdasarkan Tabel 4.13, proses pelatihan pada eksperimen BPNNS-C1 mencapai kondisi konvergensi pada epoch ke-61 dengan waktu komputasi sekitar 2 ms / step. Pada epoch tersebut diperoleh model mencapai training loss sebesar 0,000312 dan validation loss 0,000460. Kesenjangan sempit antara kedua nilai loss tersebut mengindikasikan kemampuan generalisasi yang memadai tanpa tanda overfitting signifikan. Kurva penurunan training loss dan validation loss selama pelatihan eksperimen BPNN-C1 divisualisasikan dalam Gambar 4.23.



Gambar 4. 23 Nilai loss pelatihan eksperimen BPNNS-C1

Selanjutnya, Gambar 4.24 menampilkan grafik komparasi antara data sebenarnya dan data prediksi harga saham ADMR yang dihasilkan dari model BPNNS-C1. Hasil visualisasi menunjukkan bahwa pola pergerakan harga hasil prediksi memiliki kemiripan yang cukup konsisten dengan data aktual. Kedua grafik bergerak mengikuti arah tren yang relatif sejajar pada setiap periode pengamatan, meskipun masih terdapat selisih nilai pada beberapa titik tertentu. Secara keseluruhan, kesesuaian pola antara data aktual dan data prediksi menunjukkan bahwa performa model BPNNS-C1 dalam memprediksi harga saham ADMR dapat dikategorikan baik, karena mampu menangkap pola pergerakan harga dan arah tren secara akurat dengan arsitektur jaringan yang relatif sederhana.



Gambar 4. 24 Perbandingan data prediksi dan aktual harga saham ADMR BPNNS-C1


4.3.12 Ekperimen BPNNS-C2

Berdasarkan Tabel 4.2 yang menyajikan rancangan eksperimen pada skenario pertama, eksperimen BPNNS-C2 merupakan model Backpropagation Neural Network (BPNN) dengan penambahan data sentimen yang menggunakan arsitektur dua hidden layer (7-32-16-1), fungsi aktivasi ReLU, optimizer Adam, dan learning rate sebesar 0,001. Pada eksperimen ini, atribut Close digunakan sebagai variabel target, sedangkan atribut lainnya, termasuk variabel sentimen, berperan sebagai variabel input. Proses pelatihan dilakukan menggunakan proporsi data 80% untuk pelatihan dan 20% untuk pengujian. Performa hasil pelatihan eksperimen BPNN-C2 dalam meramalkan harga saham ADMR tersaji pada Tabel 4.14.

Tabel 4. 14 Proses eksperimen BPNNS-C2


Epoch	Waktu Konvergensi	Training Loss	Validation Loss
1	21 ms / step	0,006454	0,003487
2	3 ms / step	0,001665	0,003375
3	2 ms / step	0,000927	0,002992
4	3 ms / step	0,000661	0,002594
5	2 ms / step	0,00055	0,002098
6	2 ms / step	0,000487	0,001674
7	2 ms / step	0,000439	0,001297
8	2 ms / step	0,000395	0,001029
9	2 ms / step	0,000362	0,000908
10	3 ms / step	0,000332	0,000865
...
93	2 ms / step	0,000298	0,000461

Berdasarkan Tabel 4.14, proses pelatihan pada eksperimen BPNNS-C2 berhenti pada epoch ke-93 dengan kecepatan konvergensi rata-rata sekitar 2 ms / step. Pada akhir pelatihan, training loss mencapai 0,000298, sementara validation loss sebesar 0,000461. Nilai loss yang rendah dan stabil ini mengindikasikan proses pembelajaran model yang optimal tanpa tanda overfitting signifikan, sebagaimana divisualisasikan dalam Gambar 4.25.

**Gambar 4. 25 Nilai loss pelatihan eksperimen BPNNS-C2**

Selanjutnya, Gambar 4.26 memperlihatkan komparasi antara data sebenarnya dan data hasil prediksi harga saham ADMR pada eksperimen BPNNS-C2. Grafik menunjukkan bahwa pola pergerakan harga prediksi memiliki kemiripan yang cukup konsisten dengan data aktual. Kedua kurva bergerak dengan tren yang relatif sejajar pada sebagian besar periode pengamatan, meskipun masih terdapat perbedaan nilai pada beberapa titik tertentu. Secara keseluruhan, kesesuaian pola

antara data aktual dan data prediksi tersebut mengindikasikan bahwa model BPNNS-C2 berhasil mengikuti tren dan dinamika fluktuasi harga saham ADMR secara akurat. Dengan demikian, performa model pada eksperimen ini dapat dikategorikan baik, terutama dalam merepresentasikan arah dan dinamika perubahan harga saham secara akurat.



Gambar 4. 26 Perbandingan data prediksi dan aktual harga saham ADMR BPNNS-C2


4.3.13 Ekperimen BPNNS-D1

Berdasarkan Tabel 4.2 yang menyajikan rancangan eksperimen pada skenario pertama, eksperimen BPNNS-D1 merupakan model Backpropagation Neural Network (BPNN) dengan penambahan data sentimen yang menggunakan arsitektur satu hidden layer (7-32-1), fungsi aktivasi ReLU, optimizer Adam, dan learning rate sebesar 0,001. Pada eksperimen ini, atribut Close digunakan sebagai variabel target, sedangkan atribut lainnya, termasuk variabel sentimen, digunakan sebagai variabel input. Proses pelatihan dilakukan dengan proporsi alokasi data 80%:20% antara training set dan test set. Hasil proses pelatihan pada eksperimen BPNNS-D1 dalam memprediksi harga saham ADMR dapat dilihat pada Tabel 4.15.

Tabel 4. 15 Proses eksperimen BPNNS-D1


Epoch	Waktu konvergensi	Training loss	Validation loss
1	21ms / step	0,006454	0,003487
2	3ms / step	0,001665	0,003375
3	2ms / step	0,000927	0,002992
4	3ms / step	0,000661	0,002594
5	2ms / step	0,00055	0,002098
6	2ms / step	0,000487	0,001674
7	2ms / step	0,000439	0,001297
8	2ms / step	0,000395	0,001029
9	2ms / step	0,000362	0,000908
10	3ms / step	0,000332	0,000865
...
61	2ms / step	3,122860	0,00046

Berdasarkan Tabel 4.15, proses pelatihan pada eksperimen BPNNS-D1 berhenti pada epoch ke-61 dengan waktu konvergensi rata-rata sekitar 2 ms / step. Nilai training loss yang diperoleh pada akhir pelatihan sebesar 3,122860, sedangkan nilai validation loss mencapai 0,000460. Temuan ini mengindikasikan bahwa model berhasil mencapai konvergensi dengan relatif cepat, walaupun terdapat kesenjangan yang cukup lebar antara training loss dan validation loss. Kurva proses pelatihan divisualisasikan pada Gambar 4.27.

**Gambar 4. 27 Nilai training loss eksperimen BPNNS-D1**

Gambar 4.28 menampilkan komparasi antara data sebenarnya dan hasil prediksi harga saham ADMR pada eksperimen BPNNS-D1. Grafik tersebut menggambarkan kesamaan pola tren antara harga riil dan prediksi, dengan kurva yang cenderung paralel sepanjang periode observasi. Walaupun deviasi masih terlihat pada beberapa titik, model berhasil merepresentasikan arah

pergerakan harga secara keseluruhan, sehingga menandakan performa BPNN-D1 yang memadai dalam meramalkan harga saham ADMR, khususnya dalam menangkap tren pergerakan harga meskipun akurasi nilai prediksi masih dapat ditingkatkan.



Gambar 4. 28 Perbandingan data prediksi dan aktual harga saham ADMR BPNN-D1


4.3.14 Ekperimen BPNN-D2

Berdasarkan Tabel 4.2 yang memaparkan rancangan eksperimen pada skenario pertama, eksperimen BPNN-D2 merupakan model Backpropagation Neural Network (BPNN) dengan penambahan data sentimen yang menggunakan arsitektur dua hidden layer (7-32-16-1), fungsi aktivasi ReLU, optimizer Adam, dan learning rate sebesar 0,001. Pada eksperimen ini, atribut Close digunakan sebagai variabel target, sedangkan atribut lainnya, termasuk variabel sentimen, berperan sebagai variabel input. Proses pelatihan dilakukan dengan rasio alokasi dataset 80%:20% antara data training dan testing. Hasil proses pelatihan model BPNN-D2 dalam memprediksi harga saham ADMR ditunjukkan pada Tabel 4.16.

Tabel 4. 16 Proses eksperimen BPNNS-D2


Epoch	Waktu konvergensi	Training loss	Validation loss
1	21ms / step	0,006454	0,003487
2	3ms / step	0,001665	0,003375
3	2ms / step	0,000927	0,002992
4	3ms / step	0,000661	0,002594
5	2ms / step	0,00055	0,002098
6	2ms / step	0,000487	0,001674
7	2ms / step	0,000439	0,001297
8	2ms / step	0,000395	0,001029
9	2ms / step	0,000362	0,000908
10	3ms / step	0,000332	0,000865
...
61	2ms / step	3,122860	0,00046

Berdasarkan Tabel 4.16, proses pelatihan pada eksperimen BPNNS-D2 berhenti pada epoch ke-61 dengan waktu konvergensi rata-rata sekitar 2 ms / step. Nilai training loss pada akhir pelatihan tercatat sebesar 3,122860, sedangkan validation loss mencapai 0,000460. Kondisi ini mengindikasikan bahwa model berhasil mencapai konvergensi optimal pada data validasi. Kurva penurunan training loss selama proses pelatihan divisualisasikan pada Gambar 4.29.

**Gambar 4. 29 Nilai loss pelatihan eksperimen BPNNS-D2**

Gambar 4.30 menggambarkan komparasi antara data sebenarnya dan hasil prediksi harga saham ADMR pada eksperimen BPNNS-D2. Grafik tersebut menampilkan keselarasan pola tren yang konsisten antara harga riil dan ramalan, dengan kurva yang cenderung paralel sepanjang periode observasi. Walaupun deviasi masih muncul pada beberapa titik, model efektif merepresentasikan arah pergerakan harga, sehingga menegaskan performa BPNNS-D2 yang baik

dalam meramalkan harga saham ADMR, terutama dalam mengikuti tren dan dinamika secara presisi.



Gambar 4. 30 Perbandingan data prediksi dan aktual harga saham ADMR BPNN-D2

4. 4 Hasil Prediksi Dengan Sentimen

Setelah seluruh eksperimen pada model Backpropagation Neural Network (BPNN) dengan integrasi data sentimen menyelesaikan tahap pelatihan, langkah selanjutnya adalah melakukan pengujian untuk mengevaluasi performa prediksi yang dihasilkan. Tahap pengujian ini bertujuan mengevaluasi ketepatan prediksi harga saham model terhadap kondisi riil serta mengukur dampak integrasi data sentimen terhadap peningkatan akurasi. Ringkasan performa seluruh eksperimen tersaji pada Tabel 4.17, yang menunjukkan semua model BPNN dengan sentimen mencapai akurasi 98,81%–99,66% serta R^2 mendekati 1. Temuan ini mengonfirmasi kemampuan model menjelaskan variasi data secara optimal, dengan kontribusi positif dari data sentimen dalam merepresentasikan dinamika harga saham.

Tabel 4. 17 Ringkasan hasil prediksi model BPNN dengan data sentimen

Eksperimen	Epoch Berhenti	Waktu Konvergensi	MSE	MAE	R² Score	Akurasi (%)
BPNNS-A1	125	4 ms / step	97,6276	57.589	0.9963	99.44
BPNNS-A1-R	108	3 ms / step	116,6024	63.874	0.9956	99.39
BPNNS-A1-L	174	3 ms / step	45,6602	35.210	0.9983	99.66
BPNNS-A1-LR1	125	2 ms / step	97,6276	57.589	0.9963	99.44
BPNNS-A1-LR3	125	2 ms / step	97,6276	57.589	0.9963	99.44
BPNNS-A2	70	3 ms / step	152,9992	103.555	0.9943	99.01
BPNNS-A2-R	63	2 ms / step	839,6472	246.212	0.9685	97.68
BPNNS-B1	98	2 ms / step	122,5321	57.531	0.9960	99.47
BPNNS-B1-L	61	2 ms / step	130,822	75.658	0.9958	99.31
BPNNS-B2	79	2 ms / step	216,0978	124.498	0.9930	98.81
BPNNS-C1	61	2 ms / step	221,3209	85.493	0.9903	99.14
BPNNS-C2	93	2 ms / step	69,3157	60.734	0.9970	99.41
BPNNS-D1	61	2 ms / step	237,4775	101.941	0.9909	99.02
BPNNS-D2	61	2 ms / step	207,9012	93.837	0.9921	99.12

Model dengan performa terbaik ditunjukkan oleh BPNNS-A1-L, yang mencapai akurasi tertinggi sebesar 99,66%, disertai dengan nilai MSE terendah sebesar 45,6602, MAE sebesar 35,210, serta R² Score sebesar 0,9983. Hasil ini menunjukkan bahwa penggunaan fungsi aktivasi Leaky ReLU pada arsitektur satu hidden layer mampu meningkatkan stabilitas pembelajaran dan ketepatan prediksi ketika data sentimen diintegrasikan ke dalam model. Performa tinggi juga ditunjukkan oleh model BPNNS-B1 dengan akurasi 99,47% dan BPNNS-C2 dengan akurasi 99,41%. Meskipun selisih akurasi antar model relatif kecil, perbedaan nilai MSE, MAE, dan R² menunjukkan adanya variasi kualitas prediksi yang dipengaruhi oleh perbedaan target variabel serta konfigurasi arsitektur yang digunakan.

Dari sisi struktur arsitektur, baik model dengan satu hidden layer maupun dua hidden layer sama-sama mampu menghasilkan performa yang sangat baik. Namun demikian, hasil pengujian tidak menunjukkan pola yang konsisten bahwa penambahan jumlah hidden layer selalu meningkatkan akurasi. Misalnya, BPNNS-B1 (satu hidden layer) unggul akurasinya dibanding BPNNS-B2 (dua hidden layer). Sebaliknya, untuk target Low, BPNNS-C2 (dua hidden layer) melebihi BPNNS-C1. Temuan ini menggarisbawahi bahwa optimalitas jumlah hidden layer ditentukan oleh karakteristik data dan interaksi variabel, bukan sekadar kompleksitas arsitektur.

Berdasarkan proses pelatihan, jumlah epoch berhenti bervariasi antara 61 hingga 174 epoch, dengan waktu konvergensi yang relatif cepat, yaitu 2–4 ms / step. Variasi jumlah epoch ini mengindikasikan bahwa setiap model membutuhkan jumlah iterasi yang berbeda untuk mencapai

kondisi optimum, tergantung pada kompleksitas pola data dan stabilitas gradien selama proses pembelajaran. Meskipun demikian, seluruh model tetap menunjukkan konvergensi yang baik dan mampu mencapai tingkat akurasi yang sangat tinggi. Secara keseluruhan, hasil pada Tabel 4.17 menegaskan bahwa integrasi data sentimen secara signifikan meningkatkan performa prediksi model BPNN. Seluruh eksperimen berhasil mencapai akurasi di atas 98%, dengan beberapa model bahkan mendekati akurasi sempurna. Model BPNNs-A1-L dapat dianggap sebagai model paling unggul berdasarkan kombinasi akurasi tertinggi, nilai kesalahan terendah, dan koefisien determinasi yang sangat tinggi. Temuan ini memperkuat kesimpulan bahwa data sentimen mampu memperkaya informasi input sehingga model lebih efektif dalam menangkap pola perubahan harga saham yang bersifat kompleks dan dinamis.

4.5 Eksperimen Dengan Sentimen Berdasarkan Karakteristik Data

Setelah dilakukan serangkaian eksperimen pada model BPNN dengan integrasi data sentimen, diperoleh bahwa model BPNNs-A1-L merupakan model dengan performa terbaik berdasarkan tingkat akurasi tertinggi, nilai kesalahan terendah, serta koefisien determinasi yang mendekati satu. Oleh karena itu, pada bagian ini model tersebut digunakan kembali untuk melakukan eksperimen lanjutan berdasarkan karakteristik pergerakan data harga saham, khususnya pada kondisi pasar yang mengalami tren naik dan turun. Eksperimen ini bertujuan untuk mengevaluasi konsistensi dan keandalan model BPNNs-A1-L dalam memprediksi harga saham ketika dihadapkan pada kondisi pasar yang berbeda. Data historis saham ADMR kemudian dikelompokkan ke dalam dua periode berdasarkan arah pergerakan tren harga, yaitu periode dengan kecenderungan naik dan periode dengan kecenderungan turun. Masing-masing periode mencakup durasi 8 bulan dengan jumlah data sebanyak 155 hari perdagangan, sehingga perbandingan kinerja model dapat dilakukan secara adil dan proporsional.

Pada periode tren naik, data yang digunakan mencakup rentang waktu Januari 2024 hingga Agustus 2024, yang merepresentasikan kondisi pasar dengan pergerakan harga saham yang cenderung meningkat secara bertahap. Sebaliknya, periode tren turun diambil pada rentang November 2022 hingga Juli 2023, yang mencerminkan kondisi pasar dengan tekanan penurunan harga saham secara relatif konsisten. Seluruh eksperimen pada bagian ini menggunakan konfigurasi model yang sama, yaitu BPNN dengan integrasi data sentimen, arsitektur neuron 7-32-1, fungsi aktivasi Leaky ReLU, optimizer Adam, dan learning rate sebesar 0,001. Dengan

menjaga konfigurasi model tetap sama, perbedaan hasil prediksi yang diperoleh dapat lebih difokuskan pada pengaruh karakteristik data, bukan pada perubahan struktur atau parameter model. Ringkasan skenario eksperimen berdasarkan karakteristik data disajikan pada Tabel 4.18.

Tabel 4. 18 Skenario eksperimen dengan sentimen berdasarkan karakteristik data

No	Periode	Jumlah Data	Tren	Penggunaan Model	Nama Pelatihan
1	Jan 2024 – Agu 2024	155	Naik	BPNNS-A1-L	BPNNS-TN
2	Nov 2022 – Jul 2023		Turun		BPNNS-TD

4.5.1 Ekperimen BPNN-TN


Berdasarkan Tabel 4.18, eksperimen BPNN-TN merupakan skenario pengujian model dengan integrasi data sentimen pada periode Januari 2024 hingga Agustus 2024, yang memiliki karakteristik tren harga naik. Pada skenario ini digunakan model BPNN-A1-L, yaitu model BPNN dengan satu (1) hidden layer dan fungsi aktivasi Leaky ReLU, rasio dataset 80%:20% antara data training dan testing, serta atribut Open sebagai variabel target. Model tersebut selanjutnya diberi nama pelatihan BPNN-TN untuk merepresentasikan kondisi tren naik.

Tabel 4. 19 Proses eksperimen BPNN-TN

Epoch	Waktu konvergensi	Training loss	Validation loss
1	159ms / step	0,181049	0,074418
2	16ms / step	0,126217	0,035352
3	15ms / step	0,088115	0,015767
4	21ms / step	0,062182	0,009795
5	17ms / step	0,045376	0,011211
6	16ms / step	0,035008	0,014301
7	15ms / step	0,02861	0,01575
8	14ms / step	0,024052	0,014443
9	13ms / step	0,02026	0,011613
10	14ms / step	0,01693	0,008926
...
200	14ms / step	0,000106	0,000685

Hasil pelatihan pada eksperimen BPNN-TN menunjukkan bahwa proses pembelajaran berlangsung hingga mencapai kondisi konvergensi pada epoch ke-200. Selama proses pelatihan, nilai training loss mengalami penurunan secara signifikan dan stabil, diikuti oleh nilai validation loss yang juga cenderung menurun hingga mencapai nilai yang sangat kecil. Pola ini menunjukkan bahwa model berhasil mengidentifikasi relasi antar data harga saham dan informasi sentimen


secara efektif tanpa mengalami overfitting yang signifikan. Visualisasi penurunan nilai training loss pada eksperimen ini ditunjukkan pada Gambar 4.31.



Gambar 4. 31 Nilai training loss eksperimen BPNNS-TN

Gambar 4.31 memperlihatkan bahwa kurva training loss pada eksperimen BPNNS-TN menurun tersebut terjadi secara konsisten seiring dengan peningkatan jumlah epoch. Tren penurunan yang stabil ini mengindikasikan bahwa proses optimisasi berjalan dengan baik dan integrasi data sentimen membantu model dalam menangkap pola pergerakan harga saham pada kondisi tren naik.

Selanjutnya, pada Gambar 4.32 diperlihatkan komparasi data sebenarnya dengan hasil prediksi harga saham ADMR dari eksperimen BPNNS-TN. Grafik ini memperlihatkan bahwa model menghasilkan prediksi yang sejalan dengan pergerakan data aktual dengan cukup akurat. Kedua garis, baik harga aktual maupun prediksi, bergerak dengan tren yang hampir sejajar pada setiap periode pengamatan, meskipun masih terdapat selisih kecil pada beberapa titik tertentu. Secara keseluruhan, kesamaan pola antara data aktual dan hasil prediksi menegaskan bahwa performa model pada eksperimen BPNNS-TN dapat dikategorikan sangat baik. Model BPNNS-A1-L yang dikombinasikan dengan data sentimen terbukti mampu menangkap arah dan dinamika tren kenaikan harga saham ADMR secara lebih presisi, sehingga layak digunakan sebagai model unggulan pada skenario tren naik.



Gambar 4. 32 Perbandingan data prediksi dan aktual harga saham ADMR BPNN-TN


4.5.2 Ekperimen BPNN-TD

Berdasarkan Tabel 4.18, eksperimen BPNN-TD merupakan skenario pengujian model dengan integrasi data sentimen pada periode November 2022 hingga Juli 2023, yang memiliki karakteristik tren harga turun. Pada skenario ini digunakan model BPNN-A1-L, yaitu model BPNN dengan satu (1) hidden layer, fungsi aktivasi Leaky ReLU, optimizer Adam, serta pembagian data dilakukan dengan proporsi 80% sebagai data latih dan 20% sebagai data uji. Atribut Open digunakan sebagai variabel target, dan konfigurasi tersebut selanjutnya diberi nama pelatihan BPNN-TD untuk merepresentasikan kondisi tren menurun.

Tabel 4. 20 Proses eksperimen BPNN-TD

Epoch	Waktu konvergensi	Training loss	Validation loss
1	108ms / step	0,771059	0,143324
2	14ms / step	0,619289	0,088839
3	13ms / step	0,490173	0,048521
4	14ms / step	0,382527	0,021907
5	15ms / step	0,293463	0,006945
6	16ms / step	0,219689	0,002137
7	14ms / step	0,160046	0,006503
8	14ms / step	0,113599	0,018811
9	14ms / step	0,079315	0,036275
10	14ms / step	0,055858	0,055242
...
61	10ms / step	0,001241	0,002203

Hasil pelatihan pada eksperimen BPNNS-TD menunjukkan bahwa proses pembelajaran mencapai kondisi konvergensi pada epoch ke-61. Selama proses pelatihan, nilai training loss terjadi penurunan yang cukup tajam sebelum akhirnya nilai tersebut menjadi stabil seiring peningkatan jumlah epoch. Nilai validation loss juga memperlihatkan pola yang relatif konsisten, meskipun terdapat sedikit fluktuasi pada beberapa epoch pertama. Pola tersebut menunjukkan bahwa model dapat menyesuaikan diri terhadap karakteristik data saat tren menurun, meskipun kondisi ini memiliki dinamika yang lebih kompleks dibandingkan ketika tren sedang naik. Gambar 4.33 menampilkan visualisasi perubahan nilai training loss selama proses pelatihan berlangsung.




Gambar 4. 33 Nilai training loss eksperimen BPNNS-TD

Gambar 4.33 memperlihatkan bahwa kurva training loss pada eksperimen BPNNS-TD menurun secara bertahap hingga mencapai nilai yang relatif kecil pada bagian akhir pelatihan. Hal ini mencerminkan bahwa proses optimisasi berjalan dengan cukup baik dan model mampu mempelajari pola hubungan antara harga saham dan informasi sentimen meskipun berada pada kondisi pasar yang menurun.

Selanjutnya, komparasi antara data yang aktual dan data hasil prediksi harga saham ADMR pada eksperimen BPNNS-TD disajikan pada Gambar 4.34. Grafik tersebut mencerminkan bahwa hasil prediksi model searah dengan pergerakan data aktual dengan cukup konsisten. Meskipun masih terdapat selisih pada beberapa titik pengamatan, terutama pada periode dengan fluktuasi harga yang tajam, secara umum garis prediksi tetap bergerak searah dengan tren data aktual. Secara keseluruhan, kesesuaian pola antara data yang aktual dan hasil prediksi

menunjukkan bahwa performa model pada eksperimen BPNNS-TD dapat dikategorikan baik. Integrasi data sentimen pada kondisi tren turun terbukti membantu model dalam menangkap arah pergerakan harga saham ADMR, meskipun tingkat akurasi relatif lebih rendah dibandingkan skenario tren naik. Temuan ini mengindikasikan bahwa karakteristik tren pasar memiliki pengaruh terhadap efektivitas pemanfaatan data sentimen dalam proses prediksi.



Gambar 4. 34 Perbandingan data prediksi dan aktual harga saham ADMR BPNNS-TD

4.5.3 Hasil Prediksi Dengan Sentimen Berdasarkan Karakteristik Data

Setelah seluruh proses eksperimen pada skenario tren naik (BPNNS-TN) dan tren turun (BPNNS-TD) diselesaikan, tahap selanjutnya adalah menganalisis hasil pengujian untuk menilai performa model BPNN dengan integrasi data sentimen berdasarkan perbedaan karakteristik data. Ringkasan hasil prediksi untuk setiap skenario terpampang pada Tabel 4.21.

Tabel 4. 21 Ringkasan hasil prediksi BPNN dengan sentimen berdasarkan karakteristik data

Eksperimen	Epoch Berhenti	Waktu Konvergensi	MSE	MAE	R ² Score	Akurasi (%)
BPNNS-TN	200	14ms / step	65,4084	5,4616	0,908	99,56
BPNNS-TD	61	10ms / step	2005,188	39,9023	0,7426	99,5

Mengacu pada Tabel 4.21, dapat dilihat bahwa model BPNNS-TN yang diterapkan pada data dengan pola tren naik menunjukkan kinerja prediksi yang sangat baik. Proses pelatihan model berhenti pada epoch ke-200 dan berhasil mencapai akurasi sebesar 99,56%, dengan nilai MSE sebesar 65,4084, MAE sebesar 5,4616, serta koefisien determinasi (R^2) mencapai 0,908. Nilai kesalahan yang relatif kecil dan koefisien determinasi yang tinggi tersebut mengindikasikan bahwa model dapat merepresentasikan sebagian besar variasi dalam data aktual pada kondisi tren naik. Hal ini mengindikasikan bahwa integrasi data sentimen sangat efektif dalam membantu model mengenali pola pergerakan harga saham ketika pasar berada dalam kondisi meningkat. Sebaliknya, pada skenario tren turun yang direpresentasikan oleh eksperimen BPNNS-TD, performa model mengalami penurunan dibandingkan dengan kondisi tren naik. Model ini berhenti pada epoch ke-61 dengan nilai akurasi sebesar 95,50%, MSE sebesar 2005,188, MAE sebesar 39,9023, serta R^2 sebesar 0,7426. Nilai kesalahan yang lebih besar dan nilai R^2 yang lebih rendah menunjukkan bahwa kompleksitas pola harga pada kondisi tren turun lebih sulit dipelajari oleh model, meskipun data sentimen telah diintegrasikan.

Perbedaan performa antara BPNNS-TN dan BPNNS-TD menegaskan bahwa karakteristik tren data memiliki pengaruh signifikan terhadap hasil prediksi, bahkan ketika menggunakan konfigurasi model dan parameter yang sama. Pada kondisi tren naik, sentimen pasar cenderung lebih konsisten dan searah dengan pergerakan harga, sehingga lebih mudah ditangkap oleh model. Sebaliknya, pada kondisi tren turun, pergerakan harga sering kali dipengaruhi oleh faktor eksternal dan volatilitas yang lebih tinggi, sehingga hubungan antara sentimen dan harga menjadi kurang stabil. Secara keseluruhan, hasil pada Tabel 4.21 menunjukkan bahwa model BPNN dengan integrasi data sentimen mampu memberikan prediksi yang sangat baik pada kedua karakteristik data. Namun demikian, model dengan karakteristik tren naik (BPNNS-TN) menunjukkan performa yang lebih unggul dibandingkan tren turun. Temuan ini memperkuat kesimpulan bahwa pemanfaatan data sentimen menjadi lebih optimal ketika diterapkan pada kondisi pasar yang relatif stabil dan memiliki arah tren yang jelas.

4.6 Kesimpulan

Prediksi harga saham yang dihasilkan dalam penelitian ini menunjukkan bahwa penggunaan model dengan satu hidden layer mampu menghasilkan grafik dengan pola pergerakan yang sangat mendekati data aktual. Kesesuaian pola antara prediksi dan nilai sebenarnya menjadi indikator bahwa penerapan model ANN dengan algoritma backpropagation telah bekerja secara efektif dalam membaca dan memprediksi tren harga saham. Hasil penelitian menunjukkan bahwa penerapan Backpropagation Neural Network (BPNN) dengan penambahan data sentimen mampu menghasilkan performa prediksi harga saham yang sangat akurat dan stabil. Secara umum, model dengan satu hidden layer telah mampu membentuk pola prediksi yang sangat mendekati data aktual, yang terlihat dari kesesuaian grafik antara nilai prediksi dan nilai sebenarnya. Temuan ini mengindikasikan bahwa algoritma backpropagation mampu beroperasi secara efisien dalam mempelajari hubungan nonlinier antara data harga saham dan sentimen pasar.

Berdasarkan ringkasan hasil dalam Tabel 4.17, bisa disimpulkan eksperimen BPNNS-A1-L tergolong sebagai model dengan performa terbaik secara keseluruhan dalam penelitian ini. Model ini mencapai akurasi tertinggi sebesar 99,66%, disertai dengan nilai R^2 sebesar 0,9983, yang menunjukkan kemampuan sangat kuat dalam menjelaskan variasi data aktual. Selain itu, nilai MSE (45,6602) dan MAE (35,210) yang paling rendah dibandingkan eksperimen lain mengindikasikan bahwa kesalahan prediksi berada pada tingkat yang sangat kecil. Temuan ini menunjukkan bahwa kombinasi satu hidden layer dengan fungsi aktivasi Leaky ReLU mampu meningkatkan kemampuan generalisasi model secara signifikan ketika dipadukan dengan informasi sentimen. Sementara itu, model BPNNS-B1 juga menunjukkan performa yang sangat baik dengan akurasi sebesar 99,47% dan nilai R^2 sebesar 0,9960. Grafik prediksi pada model ini memperlihatkan kesesuaian pola yang sangat stabil terhadap data aktual, sehingga tetap dapat dikategorikan sebagai model yang andal. Namun demikian, jika dibandingkan secara kuantitatif, performa BPNNS-B1 masih berada sedikit di bawah BPNNS-A1-L.

Berdasarkan Tabel 4.21, hasil prediksi yang ditinjau dari karakteristik data menunjukkan bahwa model BPNNS-TN (tren naik) menghasilkan performa yang lebih baik dibandingkan BPNNS-TD (tren turun). Hal ini terlihat dari nilai akurasi yang lebih tinggi (99,56%), serta nilai kesalahan (MSE dan MAE) yang jauh lebih rendah pada data dengan tren naik. Temuan ini mengindikasikan bahwa model BPNN dengan sentimen lebih efektif dalam mempelajari pola

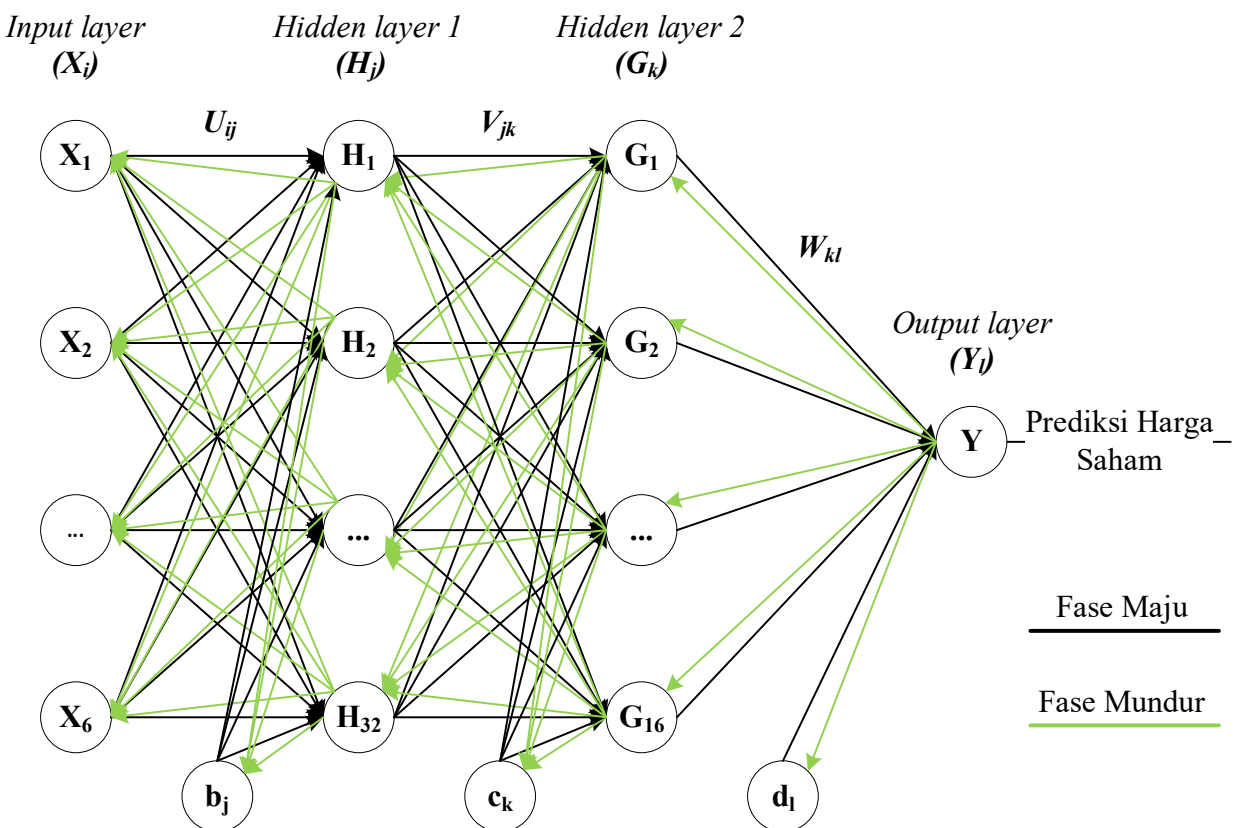
harga saham pada kondisi pasar yang stabil dan cenderung meningkat, dibandingkan pada kondisi pasar dengan tren menurun yang lebih fluktuatif. Secara keseluruhan, penelitian ini menegaskan bahwa penambahan data sentimen memberikan kontribusi signifikan terhadap peningkatan performa prediksi, baik dari sisi akurasi maupun kemampuan generalisasi model. **BPNNs-A1-L** dapat dinyatakan sebagai arsitektur paling optimal dalam penelitian ini, sedangkan analisis berdasarkan karakteristik data menunjukkan bahwa kondisi tren pasar merupakan faktor penting yang memengaruhi keberhasilan model dalam memprediksi harga saham.

BAB V

MODEL ANN-BACKPROPAGATION TANPA SENTIMEN

5.1 Desain

Penelitian ini memanfaatkan dua konfigurasi arsitektur jaringan, yaitu satu hidden layer (6-32-1) serta dua hidden layer (6-32-16-1). Model yang digunakan merupakan Artificial Neural Network (ANN) dengan algoritma backpropagation (BPNN) tanpa melibatkan data sentimen. Arsitektur BPNN tersebut memiliki tujuh neuron pada lapisan input, dua lapisan tersembunyi, dan satu neuron pada lapisan output. Model BPNN tanpa sentimen dalam penelitian ini termasuk dalam kategori metode pembelajaran terawasi (*supervised learning*) tanpa menggunakan data sentiment pada saat proses prediksi. Secara lebih detail arsitektur tersebut disajikan pada Gambar 5.1.



Gambar 5.1 Arsitektur BPNN tanpa sentimen

Desain jaringan pada skenario kedua terdiri dari data masukan (X_i) mencakup enam atribut yang mewakili kombinasi data historis dan sentimen pasar ADMR, yaitu Date, Open, High, Low, Close, dan Volume (X_1 - X_6). Seluruh input ini menjadi dasar bagi model untuk mempelajari pola harga saham secara historis. Pada tahap berikutnya, setiap neuron input terhubung ke hidden layer pertama (H_1 - H_{32}) melalui nilai pembobotan U_{ij} , disertai nilai bias b_j . Hidden layer pertama terdiri dari 32 neuron, yang menghasilkan keluaran H_j setelah melalui fungsi aktivasi. Keluaran dari layer tersembunyi pertama lalu diteruskan ke hidden layer kedua (G_1 - G_{16}) yang berisi 16 neuron melalui pembobotan V_{jk} dan bias c_k , sehingga menghasilkan output intermediate G_k . Lapisan kedua ini berfungsi memperdalam proses ekstraksi pola non-linear dari hubungan antara variabel teknikal pada proses prediksi saham ADMR.

5.2 Implementasi

Selanjutnya, arsitektur model pada penelitian ini dibangun menggunakan program *Visual Studio Code* yang terdiri baik arsitektur dengan satu hidden layer maupun dua hidden layer digunakan dalam setiap eksperimen penelitian. Selama tahap evaluasi, proses optimasi arsitektur jaringan dilakukan dengan mempertimbangkan nilai *Mean Squared Error* (MSE). berdasarkan eksperimen yang telah ditentukan sebelumnya. Sementara itu, pada proses *training*, model BPNN dengan variabel sentimen menggunakan sejumlah parameter pelatihan yang meliputi jumlah neuron, fungsi aktivasi, nilai learning rate, maksimum epoch, serta pembagian data pelatihan dan pengujian. Sedangkan, pada proses *training*, model BPNN tanpa sentimen parameter yang digunakan untuk melakukan prediksi harga saham disajikan dalam Tabel 5.1

Tabel 5. 1 Parameter model prediksi harga saham ADMR

Parameter	Variasi Nilai yang Diuji	Alasan Pemilihan
Model jaringan	Backpropagation	Stabil dan umum digunakan untuk regresi time series
Fungsi aktivasi hidden layer	ReLU, Leaky ReLU	Mengatasi non-linearitas dan vanishing gradient
Fungsi aktivasi output layer	Linear	Sesuai untuk prediksi nilai kontinu
Optimizer	Adam, RMSprop	Adaptif terhadap data volatil dan noise
Fungsi loss	MSE, MAE, R2	MSE sensitif terhadap error besar, MAE lebih robust
Jumlah neuron input layer	6 neuron	Menyesuaikan skenario dengan dan tanpa sentimen
Jumlah hidden layer	1–2 layer	Menguji kedalaman jaringan pada data kompleks
Hidden layer pertama	32 neuron	Menangkap pola non-linier tingkat awal
Hidden layer kedua	32, 16 neuron	Memodelkan interaksi fitur yang lebih kompleks
Output layer	1 neuron	Prediksi satu nilai harga saham
Learning rate	0,0001; 0,001; 0,01	Menyesuaikan kecepatan konvergensi data fluktuatif
Epoch maksimum	200, 300	Menghindari underfitting dan overfitting
Normalisasi data	Min–Max Scaling	Menyamakan skala fitur berbeda
Skema pembagian data	80:20	Menyesuaikan ukuran data
Karakteristik data	Non-linier	Mendasari pemilihan arsitektur dan parameter
Kriteria evaluasi akhir	MSE terendah & stabil	Menentukan model terbaik

5. 3 Eksperimen

Pada skenario kedua, proses eksperimen dilakukan dengan cara melatih model BPNN menggunakan pembagian data ke dalam dua kelompok, yaitu data pelatihan dan data pengujian. Pembagian dilakukan dengan proporsi 80% data digunakan untuk melatih model dan 20% sisanya untuk menguji hasil prediksi, dengan total sekitar 565 data pelatihan dan 141 data pengujian setelah melalui tahap normalisasi. Tujuan pembagian ini adalah agar model tidak hanya mengenali pola dari data yang telah dipelajari, tetapi juga dapat dievaluasi kemampuannya dalam melakukan prediksi pada data yang belum pernah digunakan dalam proses pelatihan. Selain itu, penentuan jumlah neuron pada setiap lapisan dan pemilihan variabel target dilakukan dengan pertimbangan yang matang, bukan secara acak, melainkan didasarkan pada hasil kajian literatur dan referensi penelitian sebelumnya. Beberapa sumber rujukan yang menjadi acuan antara lain penelitian (Aqila *et al.*, 2019), Bailey (2005), Fausett (1994), Sahi *et al.* (2023), dan Thomas *et al.* (2017) yang memberikan landasan teoretis mengenai desain arsitektur jaringan saraf. Dengan mengacu pada temuan tersebut, model yang digunakan dalam penelitian ini diharapkan mampu memberikan hasil yang lebih relevan dan sesuai dengan konteks pergerakan harga saham. Secara lebih detail, rangkaian proses eksperimen untuk skenario kedua dapat dilihat pada Tabel 5.2 yang menyajikan konfigurasi arsitektur dan parameter pelatihan yang diterapkan.

Tabel 5. 2 Eksperimen skenario kedua

Model	Arsitektur Neuron	Aktivasi Hidden	Optimizer	Learning Rate	Nama Pelatihan
BPNN tanpa Sentimen	6-32-1	ReLU	Adam	0,001	BPNN-A1
BPNN tanpa Sentimen	6-32-1	ReLU	RMSprop	0,001	BPNN-A1-R
BPNN tanpa Sentimen	6-32-1	Leaky ReLU	Adam	0,001	BPNN-A1-L
BPNN tanpa Sentimen	6-32-1	ReLU	Adam	0,0001	BPNN-A1-LR1
BPNN tanpa Sentimen	6-32-1	ReLU	Adam	0,01	BPNN-A1-LR3
BPNN tanpa Sentimen	6-32-16-1	ReLU	Adam	0,001	BPNN-A2
BPNN tanpa Sentimen	6-32-16-1	ReLU	RMSprop	0,001	BPNN-A2-R
BPNN tanpa Sentimen	6-32-1	ReLU	Adam	0,001	BPNN-B1
BPNN tanpa Sentimen	6-32-1	Leaky ReLU	Adam	0,001	BPNN-B1-L
BPNN tanpa Sentimen	6-32-16-1	ReLU	Adam	0,001	BPNN-B2
BPNN tanpa Sentimen	6-32-1	ReLU	Adam	0,001	BPNN-C1
BPNN tanpa Sentimen	6-32-16-1	ReLU	Adam	0,001	BPNN-C2
BPNN tanpa Sentimen	6-32-1	ReLU	Adam	0,001	BPNN-D1
BPNN tanpa Sentimen	6-32-16-1	ReLU	Adam	0,001	BPNN-D2

Untuk mengetahui kinerja model dalam memprediksi harga saham ADMR tanpa melibatkan informasi sentimen, penelitian ini menyusun serangkaian eksperimen pada skenario kedua sebagaimana ditampilkan pada Tabel 5.2. Pada skenario ini, model yang digunakan adalah Backpropagation Neural Network (BPNN) tanpa data sentimen, dengan enam variabel sebagai input, yaitu Date, Open, High, Low, Close, dan Volume. Eksperimen awal menggunakan arsitektur satu hidden layer (6–32–1) dengan fungsi aktivasi ReLU, optimizer Adam, dan learning rate sebesar 0,001, yang diberi kode BPNN-A1. Untuk menganalisis pengaruh pemilihan optimizer, konfigurasi yang sama kemudian diuji menggunakan RMSprop dan direpresentasikan oleh eksperimen BPNN-A1-R. Selain itu, pengaruh fungsi aktivasi juga dievaluasi dengan mengganti ReLU menjadi Leaky ReLU, yang dikodekan sebagai BPNN-A1-L.

Penelitian ini turut mengeksplorasi sensitivitas model terhadap variasi learning rate. Dua nilai tambahan digunakan, yaitu 0,0001 dan 0,01, yang masing-masing diberi kode BPNN-A1-LR1 dan BPNN-A1-LR3, sementara parameter lainnya dipertahankan tetap. Untuk menilai pengaruh kompleksitas arsitektur jaringan, eksperimen selanjutnya menggunakan arsitektur dua hidden layer (6–32–16–1) dengan optimizer Adam dan RMSprop, yang masing-masing diberi kode BPNN-A2 dan BPNN-A2-R. Pendekatan eksperimen yang sama kemudian diterapkan pada target prediksi yang berbeda. Ketika atribut High dijadikan sebagai variabel target, eksperimen dengan satu dan dua hidden layer masing-masing dikodekan sebagai BPNN-B1 dan BPNN-B2.

Untuk atribut Low, konfigurasi tersebut direpresentasikan oleh BPNN-C1 dan BPNN-C2, sedangkan ketika atribut Close dijadikan target prediksi, eksperimen masing-masing diberi kode BPNN-D1 dan BPNN-D2.


5.3.1 Eksperimen BPNN-A1

Berdasarkan Tabel 5.2 yang menyajikan rancangan eksperimen pada skenario kedua, eksperimen BPNN-A1 merupakan model Backpropagation Neural Network (BPNN) tanpa data sentimen yang menggunakan arsitektur satu hidden layer (6-32-1), fungsi aktivasi ReLU, optimizer Adam, serta learning rate sebesar 0,001. Pada eksperimen ini, atribut Open digunakan sebagai variabel target, sedangkan atribut lainnya, yaitu Date, High, Low, Close, dan Volume, berperan sebagai variabel input. Proses pelatihan dilakukan dengan proporsi pembagian data sebesar 80% untuk pelatihan dan 20% untuk pengujian. Hasil proses pelatihan model BPNN-A1 dalam memprediksi harga saham ADMR ditunjukkan dalam Tabel 5.3.

Tabel 5. 3 Pengolahan eksperimen BPNN-A1


Epoch	Waktu konvergensi	Training loss	Validation loss
1	21ms / step	0,131926	0,064884
2	2ms / step	0,005715	0,039767
3	2ms / step	0,002021	0,023885
4	2ms / step	0,000749	0,012132
5	2ms / step	0,000324	0,009612
6	3ms / step	0,000215	0,008119
7	2ms / step	0,00018	0,007756
8	2ms / step	0,000164	0,007635
9	4ms / step	0,000152	0,007514
10	2ms / step	0,000143	0,007462
...
60	3ms / step	0,000314	0,001474

Berdasarkan Tabel 5.3, proses pelatihan pada eksperimen BPNN-A1 berhenti pada epoch ke-60 dengan waktu konvergensi rata-rata sekitar 3 ms / step. Pada akhir proses pelatihan, nilai training loss tercatat sebesar 0,000314, sementara nilai validation loss mencapai 0,001474. Hasil ini mengindikasikan bahwa model telah mencapai titik konvergensi dan memiliki kemampuan generalisasi yang cukup baik terhadap data validasi. Gambar 5.2 memperlihatkan visualisasi penurunan nilai training loss selama proses pelatihan berlangsung.



Gambar 5. 2 Nilai training loss eksperimen BPNN-A1

Selanjutnya, Gambar 5.3 memperlihatkan perbandingan antara data sebenarnya dan data hasil prediksi harga saham ADMR pada eksperimen BPNN-A1. Grafik tersebut menunjukkan adanya kemiripan pola pergerakan yang cukup konsisten antara harga sebenarnya dan harga prediksi, di mana kedua kurva bergerak dengan tren yang relatif sejajar pada sebagian besar periode pengamatan. Meskipun masih terdapat selisih pada beberapa titik tertentu, model mampu merepresentasikan pola pergerakan harga dengan cukup baik. Secara keseluruhan, kesesuaian pola antara data aktual dan data prediksi tersebut mengindikasikan bahwa model BPNN-A1 memiliki performa yang andal dalam memprediksi harga saham ADMR, khususnya dalam menggapai arah dan tren pergerakan harga secara presisi.



Gambar 5.3 Perbandingan data prediksi dan aktual harga saham ADMR BPNN-A1


5.3.2 Eksperimen BPNN-A1-R

Berdasarkan Tabel 5.2 pada skenario kedua, eksperimen BPNN-A1-R merupakan model Backpropagation Neural Network (BPNN) tanpa sentimen yang menggunakan arsitektur satu hidden layer (6-32-1) dengan fungsi aktivasi ReLU, optimizer RMSprop, serta learning rate sebesar 0,001. Pada eksperimen ini, atribut Open digunakan sebagai variabel target, sedangkan variabel *Date*, *High*, *Low*, *Close*, serta *Volume* berperan sebagai variabel input. Proses pelatihan dilakukan dengan rasio pembagian data dilakukan dengan rasio 80% digunakan sebagai data latih dan 20% sebagai data uji. Hasil proses pelatihan model BPNN-A1-R dalam memprediksi harga saham ADMR disajikan pada Tabel 5.4.

Tabel 5.4 Proses eksperimen BPNN-A1-R


Epoch	Waktu konvergensi	Training loss	Validation loss
1	22ms / step	0,131926	0,064884
2	2ms / step	0,005715	0,039767
3	2ms / step	0,002021	0,023885
4	3ms / step	0,000749	0,012132
5	2ms / step	0,000324	0,009612
6	3ms / step	0,000215	0,008119
7	2ms / step	0,00018	0,007756
8	3ms / step	0,000164	0,007635
9	3ms / step	0,000152	0,007514
10	2ms / step	0,000143	0,007462
...
60	3ms / step	5,822175	0,005433

Berdasarkan Tabel 5.4, proses pelatihan pada eksperimen BPNN-A1-R berhenti pada epoch ke-60 dengan waktu konvergensi rata-rata sekitar 3 ms / step. Pada akhir pelatihan, nilai training loss tercatat sebesar 5,822175, sedangkan nilai validation loss sebesar 0,005433. Hasil ini menunjukkan bahwa model telah mencapai kondisi konvergen, meskipun masih terdapat selisih antara nilai loss pada data latih dan data validasi. Visualisasi perubahan nilai training loss selama proses pelatihan ditunjukkan dalam Gambar 5.4.



Gambar 5. 4 Nilai loss pelatihan eksperimen BPNN-A1-R

Selanjutnya, Gambar 5.5 menampilkan komparasi antara data sebenarnya dan data hasil prediksi harga saham ADMR pada eksperimen BPNN-A1-R. Grafik tersebut menunjukkan bahwa pola pergerakan harga prediksi memiliki kemiripan yang cukup konsisten dengan harga aktual, di mana kedua kurva bergerak dengan arah tren yang relatif sejajar pada sebagian besar periode pengamatan. Walaupun ditemukan beberapa perbedaan nilai pada beberapa titik tertentu, model tetap mampu merepresentasikan pola pergerakan harga secara umum dengan baik. Secara keseluruhan, hasil ini mengindikasikan bahwa model BPNN-A1-R memiliki performa yang cukup baik dalam memprediksi harga saham ADMR, khususnya dalam menangkap arah dan tren pergerakan harga, meskipun akurasi numeriknya masih dapat ditingkatkan melalui pengaturan parameter lebih lanjut.



Gambar 5.5 Perbandingan data prediksi dan aktual harga saham ADMR BPNN-A1-R


5.3.3 Eksperimen BPNN-A1-L

Berdasarkan Tabel 5.2 pada skenario kedua, eksperimen BPNN-A1-L merupakan model Backpropagation Neural Network (BPNN) tanpa sentimen yang menggunakan arsitektur satu hidden layer (6-32-1) dengan fungsi aktivasi Leaky ReLU, optimizer Adam, serta learning rate sebesar 0,001. Pada eksperimen ini, atribut High digunakan sebagai variabel target, sedangkan atribut Date, Open, Low, Close, dan Volume digunakan sebagai variabel input. Proses pelatihan dilakukan dengan pembagian data menggunakan rasio 80% data latih dan 20% data uji.

Tabel 5.5 Proses eksperimen BPNN-A1-L


Epoch	Waktu konvergensi	Training loss	Validation loss
1	22ms / step	0,131926	0,064884
2	2ms / step	0,005715	0,039767
3	2ms / step	0,002021	0,023885
4	3ms / step	0,000749	0,012132
5	2ms / step	0,000324	0,009612
6	3ms / step	0,000215	0,008119
7	2ms / step	0,00018	0,007756
8	3ms / step	0,000164	0,007635
9	3ms / step	0,000152	0,007514
10	2ms / step	0,000143	0,007462
...
60	3ms / step	0,000101	0,001236

Model BPNN-A1-L pada proses pelatihan mencapai konvergensi pada epoch ke-60, dengan waktu konvergensi rata-rata sekitar 3 ms / step. Di akhir pelatihan, nilai training loss tercatat sebesar 0,000101 dan validation loss sebesar 0,001236. Nilai loss yang rendah ini menandakan kemampuan model dalam menangkap pola data secara efektif serta menunjukkan stabilitas generalisasi terhadap data pengujian. Gambar 5.6 menampilkan visualisasi perubahan nilai training loss selama proses pelatihan.



Gambar 5. 6 Nilai training loss eksperimen BPNN-A1-L

Selanjutnya, Gambar 5.7 memperlihatkan perbandingan antara data aktual dan data hasil prediksi harga saham ADMR pada eksperimen BPNN-A1-L. Grafik tersebut menunjukkan adanya pola kemiripan yang cukup konsisten antara harga aktual dan harga prediksi, di mana kedua grafik bergerak dengan tren yang relatif sejajar pada sebagian besar periode pengamatan. Meskipun masih terdapat beberapa perbedaan nilai pada titik tertentu, model tetap mampu merepresentasikan pola pergerakan harga saham secara umum dengan baik. Secara keseluruhan, hasil eksperimen ini menunjukkan bahwa model BPNN-A1-L memiliki performa yang baik dalam memprediksi harga saham ADMR, khususnya dalam menangkap arah dan tren pergerakan harga. Penggunaan fungsi aktivasi Leaky ReLU terbukti membantu model dalam mengurangi permasalahan neuron mati serta meningkatkan stabilitas proses pembelajaran dibandingkan dengan fungsi aktivasi ReLU standar.



Gambar 5. 7 Perbandingan data prediksi dan aktual harga saham ADMR BPNN-A1-L


5.3.4 Eksperimen BPNN-A1-LR1

Berdasarkan Tabel 5.2 pada skenario kedua, eksperimen BPNN-A1-LR1 merupakan model Backpropagation Neural Network (BPNN) tanpa sentimen yang menggunakan arsitektur satu hidden layer (6-32-1) dengan fungsi aktivasi ReLU, optimizer Adam, serta learning rate sebesar 0,0001. Eksperimen ini dirancang untuk menganalisis pengaruh penurunan learning rate terhadap kinerja model dalam memprediksi harga saham ADMR. Atribut High digunakan sebagai variabel target, dengan rasio pembagian data 80% data latih dan 20% data uji.

Tabel 5. 6 Proses eksperimen BPNN-A1-LR1


Epoch	Waktu konvergensi	Training loss	Validation loss
1	22ms / step	0,131926	0,064884
2	2ms / step	0,005715	0,039767
3	2ms / step	0,002021	0,023885
4	3ms / step	0,000749	0,012132
5	2ms / step	0,000324	0,009612
6	3ms / step	0,000215	0,008119
7	2ms / step	0,00018	0,007756
8	3ms / step	0,000164	0,007635
9	3ms / step	0,000152	0,007514
10	2ms / step	0,000143	0,007462
...
60	3ms / step	3,555280	0,008874

Hasil proses pelatihan menunjukkan bahwa model BPNN-A1-LR1 mencapai kondisi konvergen pada epoch ke-60, dengan waktu konvergensi rata-rata sekitar 3 ms / step. Pada akhir proses pelatihan, diperoleh nilai training loss sebesar 3,555280 dan validation loss sebesar 0,008874. Nilai validation loss yang relatif lebih besar dibandingkan beberapa eksperimen sebelumnya mengindikasikan bahwa penggunaan learning rate yang terlalu kecil menyebabkan proses pembelajaran berjalan lebih lambat dan kurang optimal dalam menyesuaikan bobot jaringan. Visualisasi perubahan nilai training loss selama proses pelatihan ditunjukkan dalam Gambar 5.8.



Gambar 5. 8 Nilai loss pelatihan eksperimen BPNN-A1-LR1

Gambar 5.9 memperlihatkan perbandingan antara harga saham ADMR aktual dengan hasil prediksi dari eksperimen BPNN-A1-LR1. Grafik ini menggambarkan bahwa meskipun arah tren prediksi mengikuti pola harga sebenarnya, terdapat perbedaan yang cukup nyata pada beberapa interval waktu. Kondisi tersebut menunjukkan bahwa model belum mampu menangkap fluktuasi harga secara akurat karena keterbatasan dalam penyesuaian bobot selama pelatihan. Secara umum, eksperimen BPNN-A1-LR1 mengindikasikan bahwa learning rate yang terlalu rendah cenderung memperlambat konvergensi dan mengurangi efektivitas model dalam memahami pola data. Walaupun model masih dapat mengikuti tren utama harga saham ADMR, akurasi prediksinya relatif lebih rendah dibandingkan eksperimen BPNN-A1 yang menggunakan learning rate lebih tinggi.



Gambar 5. 9 Perbandingan data prediksi dan aktual harga saham ADMR BPNN-A1-LR1


5.3.5 Eksperimen BPNN-A1-LR3

Berdasarkan Tabel 5.2 pada skenario kedua, eksperimen BPNN-A1-LR3 merupakan model Backpropagation Neural Network (BPNN) tanpa sentimen yang menggunakan arsitektur satu hidden layer (6-32-1) dengan fungsi aktivasi ReLU, optimizer Adam, serta learning rate sebesar 0,01. Eksperimen ini dirancang untuk menganalisis pengaruh peningkatan nilai learning rate terhadap kinerja model dalam memprediksi harga saham ADMR. Pada eksperimen ini, atribut Low digunakan sebagai variabel target, dengan rasio pembagian data 80% sebagai data latih dan 20% sebagai data uji.

Tabel 5. 7 Proses eksperimen BPNN-A1-LR3


Epoch	Waktu konvergensi	Training loss	Validation loss
1	22ms / step	0,131926	0,064884
2	2ms / step	0,005715	0,039767
3	2ms / step	0,002021	0,023885
4	3ms / step	0,000749	0,012132
5	2ms / step	0,000324	0,009612
6	3ms / step	0,000215	0,008119
7	2ms / step	0,00018	0,007756
8	3ms / step	0,000164	0,007635
9	3ms / step	0,000152	0,007514
10	2ms / step	0,000143	0,007462
...
60	3ms / step	0,000162	0,001149

Hasil pelatihan menunjukkan bahwa model BPNN-A1-LR3 mencapai kondisi konvergen pada epoch ke-60, dengan waktu konvergensi rata-rata sekitar 3 ms / step. Pada akhir proses pelatihan, didapatkan nilai training loss sebesar 0,000162 serta validation loss sebesar 0,001149. Nilai training loss yang rendah ini mengindikasikan bahwa peningkatan learning rate berhasil mempercepat proses pembelajaran dan memungkinkan model menyesuaikan bobot jaringan dengan lebih efisien, tanpa menyebabkan ketidakstabilan yang berarti selama pelatihan. Gambar 5.10 menampilkan visualisasi perubahan nilai training loss sepanjang proses pelatihan.



Gambar 5. 10 Nilai training loss eksperimen BPNN-A1-LR3

Selanjutnya, Gambar 5.11 menyajikan perbandingan antara data aktual dan data hasil prediksi harga saham ADMR pada eksperimen BPNN-A1-LR3. Grafik tersebut menunjukkan bahwa pola pergerakan harga hasil prediksi memiliki kemiripan yang cukup konsisten dengan data aktual. Kedua grafik bergerak dengan tren yang hampir sejajar pada setiap periode pengamatan, meskipun masih terdapat beberapa selisih pada titik-titik tertentu. Hal ini mengindikasikan bahwa model mampu mereplikasi pola pergerakan harga dengan baik dan menangkap arah tren harga secara akurat. Secara keseluruhan, eksperimen BPNN-A1-LR3 menunjukkan bahwa penggunaan learning rate yang lebih besar dapat meningkatkan kecepatan konvergensi dan kemampuan model dalam mempelajari pola data harga saham ADMR. Dibandingkan dengan eksperimen BPNN-A1-LR1, model pada eksperimen ini menghasilkan prediksi yang lebih stabil dan akurat, khususnya dalam mengikuti tren pergerakan harga, sehingga dapat dikategorikan memiliki performa yang lebih baik pada skenario prediksi dengan satu hidden layer.



Gambar 5. 11 Perbandingan data prediksi dan aktual harga saham ADMR BPNN-A1-LR3


5.3.6 Eksperimen BPNN-A2

Berdasarkan Tabel 5.2 pada skenario kedua, eksperimen BPNN-A2 merupakan model Backpropagation Neural Network (BPNN) tanpa sentimen yang menggunakan arsitektur dua hidden layer (6-32-16-1) dengan fungsi aktivasi ReLU, optimizer Adam, serta learning rate sebesar 0,001. Eksperimen ini dirancang untuk menganalisis pengaruh penambahan jumlah hidden layer terhadap kinerja model dalam memprediksi harga saham ADMR. Pada eksperimen ini, atribut Low digunakan sebagai variabel target, dengan rasio pembagian data 80% sebagai data latih dan 20% sebagai data uji.

Tabel 5. 8 Proses eksperimen BPNN-A2


Epoch	Waktu konvergensi	Training loss	Validation loss
1	22ms / step	0,131926	0,064884
2	2ms / step	0,005715	0,039767
3	2ms / step	0,002021	0,023885
4	3ms / step	0,000749	0,012132
5	2ms / step	0,000324	0,009612
6	3ms / step	0,000215	0,008119
7	2ms / step	0,00018	0,007756
8	3ms / step	0,000164	0,007635
9	3ms / step	0,000152	0,007514
10	2ms / step	0,000143	0,007462
...
60	2ms / step	7,092130	0,005744

Hasil pelatihan menunjukkan bahwa model BPNN-A2 mencapai kondisi konvergen pada epoch ke-60, dengan waktu konvergensi rata-rata sekitar 2 ms / step. Pada akhir proses pelatihan, tercatat nilai training loss sebesar 7,092130 dan validation loss sebesar 0,005744. Nilai validation loss yang lebih rendah dibandingkan training loss menandakan kemampuan generalisasi model yang baik terhadap data pengujian. Penambahan lapisan tersembunyi memungkinkan jaringan menangkap pola nonlinier yang lebih rumit pada data harga saham. Gambar 5.12 memperlihatkan visualisasi perubahan nilai training loss selama proses pelatihan.



Gambar 5. 12 Nilai training loss eksperimen BPNN-A2

Selanjutnya, Gambar 5.13 menampilkan perbandingan antara data aktual dan data hasil prediksi harga saham ADMR pada eksperimen BPNN-A2. Grafik tersebut menunjukkan adanya kemiripan pola yang cukup konsisten antara harga aktual dan harga hasil prediksi. Kedua grafik bergerak dengan tren yang hampir sejajar pada sebagian besar periode pengamatan, meskipun masih terdapat beberapa selisih pada titik-titik tertentu. Hal ini menunjukkan bahwa model mampu mereplikasi pola pergerakan harga dengan baik dan menangkap arah tren harga secara akurat. Secara keseluruhan, eksperimen BPNN-A2 menunjukkan bahwa penggunaan arsitektur dengan dua hidden layer mampu meningkatkan kemampuan model dalam mempelajari pola pergerakan harga saham ADMR. Meskipun nilai training loss relatif lebih besar, kestabilan validation loss serta kecocokan pola prediksi dengan data sebenarnya menunjukkan bahwa model memiliki kinerja yang baik dan dapat dijadikan pembanding terhadap arsitektur dengan satu hidden layer pada kondisi tanpa data sentimen.



Gambar 5. 13 Perbandingan data prediksi dan aktual harga saham ADMR BPNN-A2


5.3.7 Eksperimen BPNN-A2-R

Berdasarkan Tabel 5.2 pada skenario kedua, eksperimen BPNN-A2-R merupakan model Backpropagation Neural Network (BPNN) tanpa sentimen yang menggunakan arsitektur dua hidden layer (6-32-16-1) dengan fungsi aktivasi ReLU, optimizer RMSprop, serta learning rate sebesar 0,001. Eksperimen ini bertujuan untuk menganalisis pengaruh penggunaan optimizer RMSprop pada arsitektur dua hidden layer terhadap kinerja model dalam memprediksi harga saham ADMR. Pada eksperimen ini, atribut Close digunakan sebagai variabel target, dengan rasio pembagian data 80% data latih dan 20% data uji.

Tabel 5. 9 Proses eksperimen BPNN-A2-R


Epoch	Waktu konvergensi	Training loss	Validation loss
1	21ms / step	0,131926	0,064884
2	2ms / step	0,005715	0,039767
3	2ms / step	0,002021	0,023885
4	2ms / step	0,000749	0,012132
5	2ms / step	0,000324	0,009612
6	3ms / step	0,000215	0,008119
7	2ms / step	0,00018	0,007756
8	2ms / step	0,000164	0,007635
9	4ms / step	0,000152	0,007514
10	2ms / step	0,000143	0,007462
...
60	2ms / step	4,889360	0,008223

Hasil pelatihan menunjukkan bahwa model BPNN-A2-R mencapai kondisi konvergen pada epoch ke-60, dengan waktu konvergensi rata-rata sekitar 2 ms / step. Pada akhir proses pelatihan, diperoleh nilai training loss sebesar 4,889360 dan validation loss sebesar 0,008223. Nilai validation loss yang relatif lebih besar dibandingkan beberapa eksperimen sebelumnya mengindikasikan bahwa penggunaan optimizer RMSprop pada konfigurasi ini belum memberikan peningkatan performa yang signifikan. Visualisasi perubahan nilai training loss selama proses pelatihan ditunjukkan pada Gambar 5.14.



Gambar 5. 14 Nilai training loss eksperimen BPNN-A2-R

Gambar 5.15 memperlihatkan perbandingan antara harga saham ADMR aktual dengan hasil prediksi dari eksperimen BPNN-A2-R. Grafik ini menggambarkan kesamaan pola pergerakan antara kedua data, di mana tren harga aktual dan prediksi cenderung berjalan sejajar pada sebagian besar periode observasi. Namun, masih ada perbedaan yang cukup nyata pada beberapa titik, yang mengindikasikan bahwa model belum mampu menangkap fluktuasi harga secara akurat penuh. Secara keseluruhan, eksperimen BPNN-A2-R menunjukkan bahwa penggunaan optimizer RMSprop pada arsitektur dua hidden layer mampu menghasilkan pola prediksi yang mengikuti tren harga saham ADMR. Namun, dibandingkan dengan eksperimen BPNN-A2 yang menggunakan optimizer Adam, performa model ini relatif lebih rendah, sehingga RMSprop belum menjadi pilihan optimal pada konfigurasi jaringan tanpa sentimen dalam skenario kedua.



Gambar 5. 15 Perbandingan data prediksi dan aktual harga saham ADMR BPNN-A2-R


5.3.8 Eksperimen BPNN-B1

Berdasarkan Tabel 5.2 pada skenario kedua, eksperimen BPNN-B1 merupakan model Backpropagation Neural Network (BPNN) tanpa sentimen yang menggunakan arsitektur satu hidden layer (6-32-1) dengan fungsi aktivasi ReLU, optimizer Adam, serta learning rate sebesar 0,001. Eksperimen ini bertujuan untuk menguji performa model BPNN tanpa data sentimen dalam memprediksi harga saham ADMR menggunakan arsitektur satu hidden layer. Variabel target yang dipilih adalah atribut Close, dengan pembagian data sebesar 80% untuk pelatihan dan 20% untuk pengujian.

Tabel 5. 10 Proses eksperimen BPNN-B1


Epoch	Waktu konvergensi	Training loss	Validation loss
1	22ms / step	0,166054	0,006575
2	3ms / step	0,003353	0,010327
3	2ms / step	0,001769	0,00879
4	3ms / step	0,001346	0,006991
5	2ms / step	0,001051	0,005737
6	3ms / step	0,000802	0,004664
7	3ms / step	0,000593	0,003827
8	2ms / step	0,000422	0,003204
9	3ms / step	0,000286	0,002758
10	2ms / step	0,000185	0,00244
...
60	2ms / step	4,889360	0,008223

Hasil pelatihan menunjukkan bahwa model BPNN-B1 mencapai kondisi konvergen pada epoch ke-60, dengan waktu konvergensi rata-rata sekitar 2 ms / step. Pada akhir proses pelatihan, diperoleh nilai training loss sebesar 4,889360 dan validation loss sebesar 0,008223. Nilai training loss yang relatif besar menunjukkan bahwa model masih mengalami keterbatasan dalam meminimalkan kesalahan selama proses pembelajaran, meskipun proses konvergensi dapat dicapai dalam jumlah epoch yang ditentukan. Visualisasi perubahan nilai training loss selama proses pelatihan ditunjukkan pada Gambar 5.16.

**Gambar 5. 16 Nilai training loss eksperimen BPNN-B1**

Selanjutnya, Gambar 5.17 memperlihatkan perbandingan antara data aktual dan data hasil prediksi harga saham ADMR pada eksperimen BPNN-B1. Grafik tersebut menunjukkan adanya

kemiripan pola pergerakan antara harga aktual dan harga hasil prediksi, di mana kedua grafik cenderung bergerak sejajar pada sebagian besar periode pengamatan. Meskipun demikian, masih terdapat beberapa selisih pada titik-titik tertentu yang menunjukkan bahwa model belum sepenuhnya mampu menangkap fluktuasi harga secara presisi. Secara keseluruhan, eksperimen BPNN-B1 menunjukkan bahwa model BPNN tanpa sentimen dengan arsitektur satu hidden layer dan optimizer Adam mampu mengikuti arah tren pergerakan harga saham ADMR dengan cukup baik. Namun, tingkat kesalahan prediksi yang masih relatif tinggi mengindikasikan bahwa konfigurasi jaringan ini belum optimal, sehingga diperlukan pengembangan lebih lanjut, seperti penambahan jumlah neuron atau hidden layer, untuk meningkatkan akurasi prediksi.



Gambar 5. 17 Perbandingan data prediksi dan aktual harga saham ADMR BPNN-B1


5.3.9 Eksperimen BPNN-B1-L

Berdasarkan Tabel 5.2 pada skenario kedua, eksperimen BPNN-B1-L merupakan model Backpropagation Neural Network (BPNN) tanpa sentimen yang menggunakan arsitektur satu hidden layer (6-32-1) dengan fungsi aktivasi Leaky ReLU, optimizer Adam, serta learning rate sebesar 0,001. Eksperimen ini dilakukan untuk menganalisis pengaruh penggunaan fungsi aktivasi Leaky ReLU terhadap kinerja model BPNN tanpa sentimen dalam memprediksi harga saham ADMR. Pada eksperimen ini, atribut Close digunakan sebagai variabel target dengan pembagian data dengan proporsi 80% untuk pelatihan dan 20% untuk pengujian.

Tabel 5. 11 Proses eksperimen BPNN-B1-L


Epoch	Waktu konvergensi	Training loss	Validation loss
1	22ms / step	0,166054	0,006575
2	3ms / step	0,003353	0,010327
3	2ms / step	0,001769	0,00879
4	3ms / step	0,001346	0,006991
5	2ms / step	0,001051	0,005737
6	3ms / step	0,000802	0,004664
7	3ms / step	0,000593	0,003827
8	2ms / step	0,000422	0,003204
9	3ms / step	0,000286	0,002758
10	2ms / step	0,000185	0,00244
...
60	2ms / step	4,889360	0,008223

Hasil pelatihan menunjukkan bahwa model BPNN-B1-L mencapai kondisi konvergen pada epoch ke-60 dengan waktu konvergensi rata-rata sekitar 2 ms / step. Pada akhir proses pelatihan, diperoleh nilai training loss sebesar 4,889360 dan validation loss sebesar 0,008223. Nilai validation loss yang masih relatif tinggi menunjukkan bahwa meskipun penggunaan fungsi aktivasi Leaky ReLU membantu menjaga aliran gradien selama proses pelatihan, model belum sepenuhnya mampu meminimalkan kesalahan prediksi secara optimal. Visualisasi perubahan nilai training loss selama proses pelatihan ditunjukkan pada Gambar 5.18.

**Gambar 5. 18 Nilai training loss eksperimen BPNN-B1-L**

Selanjutnya, Gambar 5.19 menampilkan perbandingan antara data aktual dan data hasil prediksi harga saham ADMR pada eksperimen BPNN-B1-L. Grafik tersebut menunjukkan bahwa

pola pergerakan harga hasil prediksi memiliki kecenderungan yang searah dengan harga aktual, di mana kedua grafik bergerak dengan tren yang relatif sejajar pada sebagian besar periode pengamatan. Meskipun begitu, masih ada perbedaan yang cukup nyata pada beberapa titik, yang menunjukkan bahwa model belum mampu sepenuhnya menangkap fluktuasi harga secara detail. Secara keseluruhan, eksperimen BPNN-B1-L menunjukkan bahwa penggunaan fungsi aktivasi Leaky ReLU pada model BPNN tanpa sentimen mampu mempertahankan stabilitas proses pelatihan dan mengikuti arah tren pergerakan harga saham ADMR dengan cukup baik. Namun, performa prediksi yang dihasilkan masih belum optimal, sehingga diperlukan pengembangan lebih lanjut, seperti penyesuaian arsitektur jaringan atau penambahan hidden layer, untuk meningkatkan akurasi prediksi harga saham.



Gambar 5. 19 Perbandingan data prediksi dan aktual harga saham ADMR BPNN-B1-L


5.3.10 Eksperimen BPNN-B2

Berdasarkan Tabel 5.2 pada skenario kedua, eksperimen BPNN-B2 merupakan model Backpropagation Neural Network (BPNN) tanpa sentimen yang menggunakan arsitektur dua hidden layer (6-32-16-1) dengan fungsi aktivasi ReLU, optimizer Adam, serta learning rate sebesar 0,001. Eksperimen ini bertujuan untuk menganalisis pengaruh penambahan jumlah hidden layer terhadap kinerja model BPNN tanpa sentimen dalam memprediksi harga saham ADMR. Pada eksperimen ini, atribut Close digunakan sebagai variabel target dengan rasio data 80% latih dan 20% uji.

Tabel 5. 12 Proses eksperimen BPNN-B2


Epoch	Waktu konvergensi	Training loss	Validation loss
1	22ms / step	0,166054	0,006575
2	3ms / step	0,003353	0,010327
3	2ms / step	0,001769	0,00879
4	3ms / step	0,001346	0,006991
5	2ms / step	0,001051	0,005737
6	3ms / step	0,000802	0,004664
7	3ms / step	0,000593	0,003827
8	2ms / step	0,000422	0,003204
9	3ms / step	0,000286	0,002758
10	2ms / step	0,000185	0,00244
...
60	2ms / step	4,889360	0,008223

Hasil pelatihan menunjukkan bahwa model BPNN-B2 mencapai kondisi konvergen pada epoch ke-60 dengan waktu konvergensi rata-rata sekitar 2 ms / step. Pada akhir proses pelatihan, diperoleh nilai training loss sebesar 4,889360 dan validation loss sebesar 0,008223. Nilai validation loss tersebut menunjukkan bahwa penambahan hidden layer meningkatkan kompleksitas model, namun belum sepenuhnya mampu menurunkan kesalahan prediksi secara signifikan dibandingkan model dengan satu hidden layer. Visualisasi perubahan nilai training loss selama proses pelatihan ditunjukkan pada Gambar 5.20.

**Gambar 5. 20 Nilai training loss eksperimen BPNN-B2**

Selanjutnya, Gambar 5.21 menampilkan perbandingan antara data aktual dan data hasil prediksi harga saham ADMR pada eksperimen BPNN-B2. Grafik tersebut menunjukkan bahwa

pola pergerakan harga hasil prediksi memiliki kecenderungan yang searah dengan harga aktual, di mana kedua grafik bergerak dengan tren yang relatif sejajar pada sebagian besar periode pengamatan. Meskipun demikian, masih terdapat beberapa selisih pada titik-titik tertentu yang mengindikasikan bahwa model belum sepenuhnya mampu menangkap fluktuasi harga secara detail. Secara keseluruhan, eksperimen BPNN-B2 menunjukkan bahwa penambahan jumlah hidden layer pada model BPNN tanpa sentimen mampu mempertahankan pola tren pergerakan harga saham ADMR dengan cukup baik. Namun, peningkatan kompleksitas jaringan belum memberikan peningkatan performa yang signifikan, sehingga diperlukan eksplorasi lebih lanjut, seperti penyesuaian jumlah neuron atau kombinasi dengan parameter pelatihan lainnya, guna menghasilkan prediksi yang lebih optimal.



Gambar 5. 21 Perbandingan data prediksi dan aktual harga saham ADMR BPNN-B2


5.3.11 Eksperimen BPNN-C1

Berdasarkan Tabel 5.2 pada skenario kedua, eksperimen BPNN-C1 merupakan model Backpropagation Neural Network (BPNN) tanpa sentimen yang menggunakan arsitektur 6-32-1 dengan satu hidden layer, fungsi aktivasi ReLU, optimizer Adam, serta learning rate sebesar 0,001. Eksperimen ini dirancang untuk menguji performa model BPNN tanpa data sentimen dalam memprediksi harga saham ADMR menggunakan arsitektur satu hidden layer. Pada eksperimen ini, atribut Close digunakan sebagai variabel target dengan rasio data sebesar 80% latih dan 20% uji.

Tabel 5. 13 Proses eksperimen BPNN-C1


Epoch	Waktu konvergensi	Training loss	Validation loss
1	22ms / step	0,166054	0,006575
2	3ms / step	0,003353	0,010327
3	2ms / step	0,001769	0,00879
4	3ms / step	0,001346	0,006991
5	2ms / step	0,001051	0,005737
6	3ms / step	0,000802	0,004664
7	3ms / step	0,000593	0,003827
8	2ms / step	0,000422	0,003204
9	3ms / step	0,000286	0,002758
10	2ms / step	0,000185	0,00244
...
60	2ms / step	4,889360	0,008223

Hasil pelatihan menunjukkan bahwa model BPNN-C1 mencapai kondisi konvergen pada epoch ke-60 dengan waktu konvergensi rata-rata sekitar 2 ms / step. Pada akhir proses pelatihan, diperoleh nilai training loss sebesar 4,889360 dan validation loss sebesar 0,008223. Nilai tersebut menunjukkan bahwa model mampu melakukan proses pembelajaran dengan stabil hingga mencapai batas iterasi yang ditentukan. Visualisasi perubahan nilai training loss selama proses pelatihan ditunjukkan pada Gambar 5.22.

**Gambar 5. 22 Nilai training loss eksperimen BPNN-C1**

Selanjutnya, Gambar 5.23 menampilkan perbandingan antara data sebenarnya dan data hasil prediksi harga saham ADMR pada eksperimen BPNN-C1. Grafik tersebut menunjukkan adanya kesesuaian pola pergerakan antara harga aktual dan harga prediksi, di mana kedua grafik

bergerak dengan tren yang relatif sejajar pada sebagian besar periode pengamatan. Meskipun demikian, masih terdapat beberapa perbedaan nilai pada titik-titik tertentu yang menunjukkan adanya selisih prediksi, terutama pada periode dengan fluktuasi harga yang cukup tajam. Secara keseluruhan, hasil eksperimen BPNN-C1 menunjukkan bahwa model BPNN tanpa sentimen dengan satu hidden layer dapat menangkap tren pergerakan harga saham ADMR secara memadai. Model ini dapat merepresentasikan arah pergerakan harga secara konsisten, meskipun tingkat akurasi pada beberapa periode masih dapat ditingkatkan melalui penyesuaian arsitektur jaringan atau parameter pelatihan lainnya.



Gambar 5. 23 Perbandingan data prediksi dan aktual harga saham ADMR BPNN-C1


5.3.12 Eksperimen BPNN-C2

Berdasarkan Tabel 5.2 pada skenario kedua, eksperimen BPNN-C2 merupakan model Backpropagation Neural Network (BPNN) tanpa sentimen yang menggunakan arsitektur 6-32-16-1, yaitu dua hidden layer, dengan fungsi aktivasi ReLU, optimizer Adam, serta learning rate sebesar 0,001. Eksperimen ini bertujuan menguji dampak penambahan lapisan tersembunyi terhadap performa model BPNN dalam memprediksi harga saham ADMR. Variabel target yang digunakan adalah Close, dengan proporsi pembagian data 80% untuk pelatihan dan 20% untuk pengujian.

Tabel 5. 14 Proses eksperimen BPNN-C2


Epoch	Waktu konvergensi	Training loss	Validation loss
1	22ms / step	0,166054	0,006575
2	3ms / step	0,003353	0,010327
3	2ms / step	0,001769	0,00879
4	3ms / step	0,001346	0,006991
5	2ms / step	0,001051	0,005737
6	3ms / step	0,000802	0,004664
7	3ms / step	0,000593	0,003827
8	2ms / step	0,000422	0,003204
9	3ms / step	0,000286	0,002758
10	2ms / step	0,000185	0,00244
...
60	2ms / step	4,889360	0,008223

Hasil pelatihan menunjukkan bahwa model BPNN-C2 mencapai kondisi konvergen pada epoch ke-60 dengan waktu konvergensi rata-rata sekitar 2 ms / step. Pada akhir proses pelatihan, diperoleh nilai training loss sebesar 4,889360 dan validation loss sebesar 0,008223. Nilai tersebut mengindikasikan bahwa model mampu melakukan proses pembelajaran secara stabil hingga mencapai batas iterasi yang ditentukan. Visualisasi perubahan nilai training loss selama proses pelatihan ditunjukkan pada Gambar 5.24.

**Gambar 5. 24 Nilai training loss eksperimen BPNN-C2**

Selanjutnya, Gambar 5.25 menampilkan perbandingan antara data sebenarnya dan data hasil prediksi harga saham ADMR pada eksperimen BPNN-C2. Grafik tersebut menunjukkan adanya kesesuaian pola pergerakan antara harga sebenarnya dan harga prediksi, di mana kedua

grafik bergerak dengan tren yang relatif sejajar pada sebagian besar periode pengamatan. Kondisi ini mengindikasikan bahwa model berhasil mengenali pola pergerakan harga saham secara memadai, meskipun masih terdapat beberapa selisih nilai pada titik-titik tertentu, khususnya pada periode dengan fluktuasi harga yang tinggi. Secara umum, hasil dari eksperimen BPNN-C2 mengindikasikan bahwa penerapan dua hidden layer pada model BPNN tanpa sentimen mampu meningkatkan kemampuan model dalam merepresentasikan pola tren pergerakan harga saham ADMR. Model ini dapat mengikuti arah pergerakan harga secara lebih konsisten dibandingkan arsitektur dengan satu hidden layer, sehingga performa prediksi yang dihasilkan dapat dikategorikan baik.



Gambar 5. 25 Perbandingan data prediksi dan aktual harga saham ADMR BPNN-C2


5.3.13 Eksperimen BPNN-D1

Berdasarkan Tabel 5.2 pada skenario kedua, eksperimen BPNN-D1 merupakan model Backpropagation Neural Network (BPNN) tanpa sentimen yang menggunakan arsitektur 6-32-1 dengan satu hidden layer. Model ini menerapkan fungsi aktivasi ReLU, optimizer Adam, serta learning rate sebesar 0,001. Eksperimen BPNN-D1 dilakukan untuk memprediksi harga saham ADMR. Variabel Close dipilih sebagai target, sementara variabel lainnya berfungsi sebagai input. Proses pelatihan dan pengujian menggunakan proporsi pembagian data 80% untuk pelatihan dan 20% untuk pengujian.

Tabel 5. 15 Proses eksperimen BPNN-D1


Epoch	Waktu konvergensi	Training loss	Validation loss
1	22ms / step	0,166054	0,006575
2	3ms / step	0,003353	0,010327
3	2ms / step	0,001769	0,00879
4	3ms / step	0,001346	0,006991
5	2ms / step	0,001051	0,005737
6	3ms / step	0,000802	0,004664
7	3ms / step	0,000593	0,003827
8	2ms / step	0,000422	0,003204
9	3ms / step	0,000286	0,002758
10	2ms / step	0,000185	0,00244
...
60	2ms / step	4,889360	0,008223

Hasil pelatihan menunjukkan bahwa model BPNN-D1 mencapai kondisi konvergen pada epoch ke-60 dengan waktu konvergensi rata-rata sekitar 2 ms / step. Pada akhir proses pelatihan, diperoleh nilai training loss sebesar 4,889360 dan validation loss sebesar 0,008223. Nilai tersebut mengindikasikan bahwa proses pembelajaran berlangsung secara stabil hingga mencapai jumlah iterasi maksimum yang ditentukan. Visualisasi perubahan nilai training loss selama proses pelatihan ditunjukkan pada Gambar 5.26.

**Gambar 5. 26 Nilai training loss eksperimen BPNN-D1**

Selanjutnya, Gambar 5.27 memperlihatkan perbandingan antara data sebenarnya dan data hasil prediksi harga saham ADMR pada eksperimen BPNN-D1. Grafik tersebut menunjukkan

adanya kesamaan pola pergerakan antara harga sebenarnya dan harga prediksi, di mana kedua kurva bergerak dengan arah tren yang relatif sejajar pada sebagian besar periode pengamatan. Meskipun demikian, masih terdapat beberapa ketidaksamaan nilai pada titik-titik tertentu, terutama pada periode dengan fluktuasi harga yang cukup tajam. Secara keseluruhan, hasil eksperimen BPNN-D1 menunjukkan bahwa model BPNN tanpa sentimen dengan satu hidden layer mampu menggapai pola pergerakan tren harga saham ADMR dengan cukup baik. Model ini dapat merepresentasikan hubungan antarvariabel secara efektif, sehingga performa prediksi yang dihasilkan dapat dikategorikan baik, meskipun masih memiliki keterbatasan dalam mengikuti perubahan harga yang bersifat ekstrem.



Gambar 5. 27 Perbandingan data prediksi dan aktual harga saham ADMR BPNN-D1


5.3.14 Eksperimen BPNN-D2

Berdasarkan Tabel 5.2 pada skenario kedua, eksperimen BPNN-D2 merupakan model Backpropagation Neural Network (BPNN) tanpa sentimen yang menggunakan arsitektur 6-32-16-1, yaitu dengan dua hidden layer. Model ini menerapkan fungsi aktivasi ReLU, optimizer Adam, serta learning rate sebesar 0,001. Eksperimen BPNN-D2 dilakukan untuk memprediksi harga saham ADMR dengan memakai atribut Close sebagai variabel target, sementara variabel lainnya berperan sebagai variabel input. Pembagian data yang dipakai dalam eksperimen ini adalah 80% data latih dan 20% data uji.

Tabel 5. 16 Proses eksperimen BPNN-D2


Epoch	Waktu konvergensi	Training loss	Validation loss
1	22ms / step	0,166054	0,006575
2	3ms / step	0,003353	0,010327
3	2ms / step	0,001769	0,00879
4	3ms / step	0,001346	0,006991
5	2ms / step	0,001051	0,005737
6	3ms / step	0,000802	0,004664
7	3ms / step	0,000593	0,003827
8	2ms / step	0,000422	0,003204
9	3ms / step	0,000286	0,002758
10	2ms / step	0,000185	0,00244
...
60	2ms / step	4,889360	0,008223

Hasil pelatihan menunjukkan bahwa model BPNN-D2 mencapai kondisi konvergen pada epoch ke-60 dengan waktu konvergensi rata-rata sekitar 2 ms / step. Pada akhir proses pelatihan, diperoleh nilai training loss sebesar 4,889360 dan validation loss sebesar 0,008223. Nilai tersebut menunjukkan bahwa proses pembelajaran berlangsung secara stabil hingga mencapai jumlah iterasi maksimum yang ditetapkan. Visualisasi perubahan nilai training loss selama proses pelatihan ditunjukkan pada Gambar 5.28.

**Gambar 5. 28 Nilai loss pelatihan eksperimen BPNN-D2**

Selanjutnya, Gambar 5.29 menampilkan grafik komparasi antara data sebenarnya dan data hasil prediksi harga saham ADMR pada eksperimen BPNN-D2. Grafik tersebut memperlihatkan adanya kesamaan pola pergerakan yang cukup konsisten antara harga aktual dan

harga prediksi. Kedua kurva bergerak dengan arah tren yang relatif sejajar pada sebagian besar periode pengamatan, meskipun masih terdapat beberapa selisih nilai pada titik-titik tertentu. Secara keseluruhan, hasil eksperimen BPNN-D2 menunjukkan bahwa penggunaan dua hidden layer mampu meningkatkan kemampuan model dalam menangkap pola nonlinier pada data harga saham ADMR. Model ini berhasil menggambarkan arah tren pergerakan harga secara efektif, sehingga performa prediksi yang dihasilkan dapat dikategorikan baik, terutama dalam mengikuti kecenderungan umum pergerakan harga saham.



Gambar 5. 29 Perbandingan data prediksi dan aktual harga saham ADMR BPNN-D2

5. 4 Hasil Prediksi Tanpa Sentimen

Setelah pelatihan selesai pada setiap eksperimen selesai dilakukan, langkah berikutnya merupakan pengujian untuk mengukur kinerja masing-masing arsitektur model Backpropagation Neural Network (BPNN) tanpa penggunaan data sentimen. Pengujian ini bertujuan untuk menentukan model dengan performa terbaik serta menganalisis pengaruh variasi arsitektur, optimizer, learning rate, dan atribut target terhadap kemampuan prediksi harga saham. Ringkasan hasil pengujian seluruh model disajikan pada Tabel 5.17.

Tabel 5. 17 Ringkasan hasil prediksi model BPNN tanpa data sentimen

Eksperimen	Epoch Berhenti	Waktu Konvergensi	MSE	MAE	R² Score	Akurasi (%)
BPNN-A1	60	3ms / step	2066,456	41,3153	0,9224	96,03
BPNN-A1-R	60	3ms / step	337,9253	15,324	0,9873	98,5
BPNN-A1-L	60	3ms / step	2341,187	43,9329	0,9121	95,73
BPNN-A1-LR1	60	3ms / step	2066,456	41,3153	0,9224	96,03
BPNN-A1-LR3	60	3ms / step	2066,456	41,3153	0,9224	96,03
BPNN-A2	60	2ms / step	1056,545	25,3962	0,9603	97,41
BPNN-A2-R	60	2ms / step	3187,875	49,0139	0,8803	95,04
BPNN-B1	60	2ms / step	1459,222	35,915	0,9527	96,62
BPNN-B1-L	60	2ms / step	2514,776	47,1858	0,9184	95,51
BPNN-B2	60	2ms / step	1934,844	33,643	0,9372	96,57
BPNN-C1	60	2ms / step	1547,607	35,2899	0,9323	96,42
BPNN-C2	60	2ms / step	797,5061	21,4761	0,9651	97,75
BPNN-D1	60	2ms / step	1816,893	38,8083	0,9308	96,15
BPNN-D2	60	2ms / step	1788,439	33,1491	0,9318	96,57

Berdasarkan Tabel 5.17, seluruh model BPNN tanpa sentimen menunjukkan proses pelatihan yang stabil, ditandai dengan seluruh eksperimen berhenti pada epoch ke-60. Hal ini menunjukkan bahwa mekanisme pelatihan yang diterapkan telah konsisten pada setiap skenario, baik untuk model dengan satu maupun dua hidden layer. Selain itu, waktu konvergensi yang dihasilkan relatif singkat, yaitu berkisar antara 2–3 ms / step, yang menandakan efisiensi proses pembelajaran pada seluruh arsitektur model. Meskipun memiliki jumlah epoch dan waktu konvergensi yang relatif seragam, performa prediksi antar eksperimen menunjukkan variasi yang cukup signifikan. Model BPNN-C2 mencatatkan performa terbaik dengan nilai MSE sebesar 797,5061, MAE sebesar 21,4761, R² sebesar 0,9651, serta tingkat akurasi tertinggi yaitu 97,75%. Hasil ini menunjukkan bahwa arsitektur dua hidden layer dengan target variabel Low mampu menangkap pola hubungan data secara lebih optimal dibandingkan model lainnya.

Performa terbaik berikutnya ditunjukkan oleh model BPNN-A2, yang memperoleh tingkat akurasi 97,41% dengan nilai R² sebesar 0,9603, serta BPNN-B1 dengan akurasi 96,62% dan R² sebesar 0,9527. Ketiga model tersebut dapat dikategorikan memiliki kualitas prediksi yang baik karena mampu menghasilkan nilai kesalahan yang relatif rendah serta koefisien determinasi yang tinggi, sehingga prediksi yang dihasilkan mendekati data aktual. Sebaliknya, beberapa model seperti BPNN-A2-R, BPNN-B1-L, dan BPNN-A1-L memperlihatkan kinerja yang lebih lemah, ditandai dengan nilai MSE dan MAE yang lebih tinggi serta nilai R² yang lebih rendah. Meskipun demikian, seluruh model masih mampu menghasilkan tingkat akurasi di atas 95%, yang

menandakan bahwa secara umum model BPNN tanpa sentimen tetap memiliki kemampuan prediksi yang cukup baik.

Variasi performa ini mencerminkan bahwa keberhasilan model tidak hanya diputuskan oleh struktur arsitektur semata, tetapi juga sangat dipengaruhi oleh pemilihan atribut target, kombinasi optimizer, serta karakteristik data yang digunakan. Model yang menggunakan atribut target dengan pola pergerakan yang lebih konsisten dan informatif, seperti pada eksperimen BPNN-C2, terbukti mampu menghasilkan performa prediksi yang lebih optimal. Sebaliknya, ketika hubungan antara atribut input dan target kurang kuat, performa model cenderung menurun meskipun konfigurasi arsitektur yang digunakan serupa. Secara keseluruhan, hasil pengujian ini menegaskan bahwa pemilihan atribut dan konfigurasi arsitektur yang tepat merupakan faktor kunci dalam meningkatkan akurasi prediksi harga saham, khususnya pada pendekatan BPNN tanpa melibatkan data sentimen.

5.5 Eksperimen Tanpa Sentimen Berdasarkan Karakteristik Data

Pada tahap ini, pengujian difokuskan pada penerapan model terbaik BPNN tanpa data sentimen, yaitu BPNN-A1-R, untuk melihat konsistensi kinerja model pada kondisi karakteristik data yang berbeda. Eksperimen dilaksanakan dengan membagi data riwayat historis harga saham ke dalam dua periode yang merepresentasikan tren naik dan tren turun, masing-masing berdurasi delapan bulan dengan jumlah data yang sama, yaitu 155 hari perdagangan. Periode Januari 2024 hingga Agustus 2024 dipilih untuk mewakili kondisi tren naik, sedangkan periode November 2022 hingga Juli 2023 digunakan untuk menggambarkan kondisi tren turun. Dengan menggunakan jumlah data yang identik pada kedua skenario, pengujian ini bertujuan untuk menentukan bahwa perbedaan performa prediksi yang dihasilkan lebih dipengaruhi oleh karakteristik tren data, bukan oleh perbedaan volume data latih.

Model BPNN-A1-R dipilih karena pada pengujian sebelumnya menunjukkan performa terbaik di antara seluruh model tanpa sentimen. Model ini menggunakan arsitektur satu hidden layer (6-32-1) dengan fungsi aktivasi ReLU, optimizer RMSprop, serta learning rate sebesar 0,001. Konfigurasi tersebut dinilai mampu memberikan proses pembelajaran yang stabil dan konvergensi yang cepat pada data harga saham tanpa dukungan informasi sentimen. Melalui skenario ini, diharapkan dapat didapatkan gambaran yang lebih jelas mengenai kemampuan model BPNN tanpa

sentimen dalam memprediksi harga saham dengan kondisi pasar yang berbeda, sekaligus menjadi pembanding terhadap hasil eksperimen dengan integrasi data sentimen pada bagian sebelumnya.

Tabel 5. 18 Skenario eksperimen tanpa sentimen berdasarkan karakteristik data

No	Periode	Jumlah Data	Tren	Penggunaan Model	Nama Pelatihan
1	Jan 2024 – Agu 2024	155	Naik	BPNN-A1-R	BPNN-TN
2	Nov 2022 – Jul 2023		Turun		BPNN-TD


5.5.1 Eksperimen BPNN-TN

Berdasarkan Tabel 5.18, skenario eksperimen BPNN-TN merupakan pengujian model tanpa data sentimen pada periode Januari 2024 hingga Agustus 2024 dengan karakteristik tren harga naik dan jumlah data sebanyak 155 hari. Model yang digunakan pada skenario ini adalah BPNN-A1-R, yaitu jaringan saraf backpropagation dengan satu hidden layer, arsitektur 6-32-1, fungsi aktivasi ReLU, optimizer RMSprop, dan learning rate 0,001.

Tabel 5. 19 Proses eksperimen BPNN-TN

Epoch	Waktu konvergensi	Training loss	Validation loss
1	61ms / step	0,150558	0,042754
2	9ms / step	0,092407	0,019255
3	10ms / step	0,063733	0,010548
4	10ms / step	0,045369	0,007952
5	9ms / step	0,032891	0,006961
6	12ms / step	0,023911	0,006511
7	11ms / step	0,017432	0,006344
8	10ms / step	0,012784	0,006646
9	10ms / step	0,009681	0,007123
10	10ms / step	0,007557	0,007496
...
60	10ms / step	0,00024	4,358485


Pada eksperimen BPNN-TN, proses pelatihan berhenti pada epoch ke-60, yang menunjukkan pencapaian konvergensi secara stabil oleh model. Nilai loss baik pada data pelatihan maupun validasi menurun secara konsisten selama training, mengindikasikan kemampuan model dalam memahami pola data tanpa tanda overfitting yang berarti. Gambar 5.30 menampilkan visualisasi proses penurunan nilai training loss pada eksperimen ini.



Gambar 5.30 Nilai training loss eksperimen BPNN-TN

Gambar 5.30 memperlihatkan bahwa kurva training loss cenderung menurun secara tajam pada awal epoch dan kemudian melandai hingga mencapai kondisi stabil menjelang akhir proses pelatihan. Pola ini menunjukkan bahwa proses optimisasi berjalan efektif dan model berhasil menemukan bobot yang optimal dalam memetakan hubungan antar variabel input terhadap target prediksi.

Selanjutnya, hasil perbandingan antara data sebenarnya dan data hasil prediksi harga saham ADMR pada eksperimen BPNN-TN disajikan pada Gambar 5.31. Grafik tersebut menunjukkan bahwa pola pergerakan harga hasil prediksi memiliki kemiripan yang cukup tinggi dengan data aktual, terutama dalam mengikuti arah tren kenaikan harga. Kedua kurva bergerak relatif sejajar pada sebagian besar periode pengamatan, walaupun masih terdapat selisih kecil pada beberapa titik tertentu. Secara keseluruhan, hasil ini mencerminkan bahwa model BPNN-TN mampu menggapai karakteristik pergerakan harga saham ADMR pada kondisi tren naik dengan baik. Kemampuan model dalam mengikuti arah tren dan menghasilkan prediksi yang mendekati data aktual menegaskan bahwa arsitektur BPNN-A1-R cukup efektif digunakan untuk prediksi harga saham tanpa melibatkan data sentimen, khususnya pada periode dengan kecenderungan tren positif.



Gambar 5. 31 Perbandingan data prediksi dan aktual harga saham ADMR BPNN-TN


5.5.2 Eksperimen BPNN-TD

Berdasarkan Tabel 5.18, eksperimen BPNN-TD merupakan skenario pengujian model tanpa data sentimen pada periode November 2022 hingga Juli 2023, yang memiliki karakteristik tren harga turun. Pada skenario ini digunakan model BPNN-A1-R dengan arsitektur satu (1) hidden layer, rasio data sebesar 80% latih dan 20% uji, serta atribut Open sebagai variabel target. Model ini selanjutnya diberi nama pelatihan BPNN-TD untuk membedakannya dari skenario tren naik.

Tabel 5. 20 Proses eksperimen BPNN-TD

Epoch	Waktu konvergensi	Training loss	Validation loss
1	59ms / step	0,573096	0,007397
2	10ms / step	0,385316	0,021198
3	9ms / step	0,278661	0,038625
4	9ms / step	0,202396	0,055661
5	11ms / step	0,143813	0,068328
6	9ms / step	0,099355	0,074905
7	11ms / step	0,0667	0,073251
8	9ms / step	0,043939	0,065368
9	10ms / step	0,02885	0,053048
10	11ms / step	0,01883	0,040804
...
61	11ms / step	0,000257	0,001605

Hasil pelatihan pada eksperimen BPNN-TD menunjukkan bahwa proses pembelajaran berhenti pada epoch ke-61, yang menandakan bahwa model telah mencapai kondisi konvergensi. Selama proses pelatihan, nilai training loss mengalami penurunan yang konsisten hingga mendekati nol, sementara nilai validation loss juga menunjukkan kecenderungan menurun dan stabil di akhir epoch. Tren ini mengindikasikan kemampuan model dalam memahami fitur data dengan baik, meskipun data memiliki pola pergerakan harga yang menurun. Visualisasi proses penurunan nilai training loss pada eksperimen ini ditampilkan pada Gambar 5.32.




Gambar 5. 32 Nilai training loss eksperimen BPNN-TN

Gambar 5.32 memperlihatkan bahwa kurva training loss pada eksperimen BPNN-TD menurun secara bertahap seiring bertambahnya jumlah epoch. Penurunan loss yang stabil menunjukkan bahwa perjalanan optimisasi berjalan dengan baik dan model mampu menyesuaikan bobot secara efektif terhadap pola data tren turun.

Selanjutnya, perbandingan antara data sebenarnya dan data hasil prediksi harga saham ADMR pada eksperimen BPNN-TD disajikan pada Gambar 5.33. Grafik tersebut menunjukkan bahwa hasil prediksi model mengikuti arah pergerakan harga aktual yang cenderung menurun. Meskipun terdapat beberapa selisih pada titik tertentu, secara umum pola prediksi masih bergerak searah dengan data sebenarnya, yang mengindikasikan kemampuan model dalam menangkap tren penurunan harga. Secara umum, hasil eksperimen BPNN-TD menunjukkan bahwa model BPNN-A1-R masih mampu menghasilkan performa prediksi yang memadai pada kondisi tren harga turun, meskipun tingkat kompleksitas pola data lebih menantang dibandingkan tren naik. Hal ini

menegaskan bahwa model BPNN tanpa sentimen masih memiliki kemampuan adaptif dalam memodelkan pergerakan harga saham ADMR pada berbagai karakteristik tren data.



Gambar 5. 33 Perbandingan data prediksi dan aktual harga saham ADMR BPNN-TD

5.5.3 Hasil Prediksi Tanpa Sentimen Berdasarkan Karakteristik Data

Setelah seluruh proses eksperimen pada skenario tren naik (BPNN-TN) dan tren turun (BPNN-TD) diselesaikan, tahap berikutnya adalah melakukan analisis terhadap hasil pengujian untuk mengevaluasi performa model BPNN tanpa integrasi data sentimen berdasarkan karakteristik data. Ringkasan hasil prediksi untuk tiap skenario ditampilkan dalam Tabel 5.21.

Tabel 5. 21 Ringkasan hasil prediksi BPNN tanpa sentimen berdasarkan karakteristik data

Eksperimen	Epoch Berhenti	Waktu Konvergensi	MSE	MAE	R ² Score	Akurasi (%)
BPNN-TN	60	10ms / step	237,8985	13,4006	0,6655	98,92
BPNN-TD	61	11ms / step	2821,826	44,0234	0,6378	95,31

Berdasarkan Tabel 5.21, model BPNN-TN yang diterapkan pada data dengan karakteristik tren naik menunjukkan performa prediksi yang sangat baik. Model ini berhenti pada epoch ke-60 dengan waktu konvergensi sekitar 10 ms / step. Hasil evaluasi menunjukkan nilai MSE sebesar 237,8985, MAE sebesar 13,4006, serta R² sebesar 0,6655, dengan tingkat akurasi mencapai 98,92%. Nilai kesalahan yang relatif kecil dan akurasi yang tinggi mengindikasikan bahwa model mampu mempelajari pola pergerakan harga saham secara efektif meskipun hanya

menggunakan data historis tanpa dukungan sentimen. Sebaliknya, pada skenario tren turun yang direpresentasikan oleh eksperimen BPNN-TD, performa model cenderung menurun dibandingkan dengan kondisi tren naik. Model ini berhenti pada epoch ke-61 dengan waktu konvergensi sekitar 11 ms / step. Nilai MSE sebesar 2821,826 dan MAE sebesar 44,0234 menunjukkan tingkat kesalahan yang lebih besar, sementara R^2 sebesar 0,6378 mengindikasikan bahwa kemampuan model dalam menjelaskan variasi data aktual pada kondisi tren turun relatif lebih rendah. Meskipun demikian, model ini masih mampu mencapai akurasi sebesar 95,31%, yang menunjukkan bahwa performa prediksi tetap berada pada kategori baik.

Perbedaan hasil antara BPNN-TN dan BPNN-TD menegaskan bahwa karakteristik tren data sangat berpengaruh terhadap kinerja model prediksi, terutama ketika data sentimen tidak digunakan. Pada kondisi tren naik, pola pergerakan harga cenderung lebih stabil dan konsisten, sehingga lebih mudah dipelajari oleh model. Sebaliknya, pada kondisi tren turun, fluktuasi harga yang lebih tajam dan tidak teratur menyebabkan peningkatan kesalahan prediksi. Secara keseluruhan, hasil pada Tabel 5.21 menunjukkan bahwa model BPNN tanpa sentimen masih mampu menghasilkan tingkat akurasi yang tinggi pada kedua karakteristik data. Namun demikian, performa terbaik diperoleh pada skenario tren naik (BPNN-TN). Temuan ini mengindikasikan bahwa meskipun data historis harga saham sudah cukup informatif, keterbatasan model tanpa sentimen menjadi lebih terlihat ketika dihadapkan pada kondisi pasar yang bersifat menurun dan lebih volatil.

5.6 Kesimpulan

Prediksi harga saham dalam penelitian ini mengindikasikan bahwa model BPNN dengan dua lapisan tersembunyi cenderung menghasilkan pola prediksi yang lebih stabil dibandingkan dengan konfigurasi satu hidden layer. Secara umum, grafik prediksi dari model-model tersebut memperlihatkan pola pergerakan yang cukup sejalan dengan data aktual, sehingga mengindikasikan bahwa algoritma backpropagation bekerja secara efektif dalam menangkap tren pergerakan harga saham.

Berdasarkan hasil pengujian pada Tabel 5.17 dan Tabel 5.21, dapat disimpulkan bahwa model Backpropagation Neural Network (BPNN) tanpa penggunaan data sentimen mampu memberikan performa prediksi harga saham yang baik dan konsisten pada berbagai konfigurasi arsitektur. Seluruh model menunjukkan proses pelatihan yang stabil dengan konvergensi yang

umumnya tercapai pada epoch ke-60, yang menandakan efektivitas algoritma backpropagation dalam mempelajari pola data historis harga saham.

Hasil pada Tabel 5.17 menunjukkan BPNN-A1-R teridentifikasi sebagai model dengan performa terbaik secara umum. Model ini menghasilkan akurasi tertinggi sebesar 98,5% dan nilai R^2 sebesar 0,9873, yang merupakan nilai tertinggi dibandingkan seluruh eksperimen lainnya. Selain itu, nilai MSE (337,9253) dan MAE (15,324) yang relatif rendah mengindikasikan bahwa prediksi yang dihasilkan memiliki tingkat kesalahan yang kecil serta mampu merepresentasikan pergerakan data aktual dengan sangat baik. Temuan ini menunjukkan bahwa konfigurasi satu hidden layer dengan aktivasi ReLU dan optimasi RMSprop sudah cukup menunjukkan kemampuan yang memadai dalam mempelajari karakteristik nonlinier pada data harga saham. Sementara itu, model BPNN-C2, yang menggunakan dua hidden layer untuk prediksi nilai Low, juga menunjukkan performa yang tinggi dengan akurasi sebesar 97,75% dan R^2 sebesar 0,9651. Meskipun tidak menjadi yang terbaik secara keseluruhan, hasil ini mengindikasikan bahwa penambahan hidden layer pada konfigurasi tertentu dapat meningkatkan stabilitas dan kemampuan pembelajaran model, terutama pada target variabel tertentu.

Berdasarkan Tabel 5.21, pengujian BPNN tanpa sentimen berdasarkan karakteristik data menunjukkan bahwa model pada kondisi tren naik (BPNN-TN) menghasilkan performa yang lebih baik dibandingkan kondisi tren turun (BPNN-TD). Hal ini terlihat dari akurasi yang lebih tinggi serta nilai kesalahan yang lebih kecil pada data dengan tren naik, yang menunjukkan bahwa model lebih mudah mempelajari pola harga pada kondisi pasar yang relatif stabil. Secara keseluruhan, hasil penelitian ini menegaskan bahwa model **BPNN-A1-R** merupakan arsitektur paling unggul dalam skenario tanpa sentimen, baik dari sisi akurasi, kemampuan generalisasi, maupun kestabilan pelatihan. Temuan ini juga menunjukkan bahwa jumlah hidden layer bukan satu-satunya faktor penentu keberhasilan model, melainkan kombinasi antara struktur jaringan, fungsi aktivasi, optimizer, serta karakteristik data yang digunakan.

BAB VI

PEMBAHASAN

6.1 Hasil dan Pembahasan

Penelitian ini dirancang untuk mengeksplorasi sejauh mana model Artificial Neural Network (ANN) mampu melakukan prediksi harga saham ADMR dengan memanfaatkan kombinasi atribut data terutama data sentiment dan berdasarkan karakteristik data. Atribut data sentimen dalam hal ini memiliki peran yang sangat vital, karena informasi yang terkandung di dalamnya akan menjadi dasar pembelajaran bagi model untuk mengenali pola maupun tren yang tersembunyi. Dengan kata lain, kualitas dan relevansi atribut input sangat menentukan apakah model dapat menghasilkan prediksi yang mendekati kenyataan atau sebaliknya.

Hasil pengujian menunjukkan bahwa atribut data memiliki pengaruh yang sangat signifikan terhadap kinerja prediksi harga saham ADMR menggunakan model Backpropagation Neural Network (BPNN). Perbandingan antara model yang menggunakan data sentimen (BPNNS) dan model tanpa data sentimen (BPNN) memperlihatkan perbedaan performa yang jelas, baik dari sisi tingkat kesalahan (MSE dan MAE) maupun kemampuan generalisasi model (R^2 Score dan akurasi). Berdasarkan ringkasan hasil prediksi BPNNS, seluruh eksperimen dengan data sentimen menghasilkan nilai R^2 Score yang sangat tinggi, yaitu berada pada rentang 0,9903 hingga 0,9983, dengan tingkat akurasi antara 98,81% hingga 99,66%. Model BPNNS-A1-L menunjukkan performa terbaik dengan MSE sebesar 45,6602, MAE sebesar 35,210, R^2 Score sebesar 0,9983, serta akurasi tertinggi sebesar 99,66%. Nilai error yang rendah dan koefisien determinasi yang mendekati satu menunjukkan bahwa model mampu mempelajari pola pergerakan harga saham secara sangat akurat ketika atribut sentimen dilibatkan.

Sebaliknya, model BPNN tanpa data sentimen menunjukkan performa yang relatif lebih rendah. Nilai MSE pada kelompok ini berada pada rentang 337,9253 hingga 3187,875, dengan R^2 Score antara 0,8803 hingga 0,9873. Meskipun beberapa model, seperti BPNN-A1-R, masih mampu mencapai akurasi yang cukup tinggi (98,5%), tingkat kesalahan yang lebih besar menunjukkan keterbatasan model dalam menangkap dinamika harga saham hanya berdasarkan

data numerik historis. Hal ini mengindikasikan bahwa atribut sentimen berperan penting dalam memperkaya informasi input model dan meningkatkan ketepatan prediksi.

Temuan ini sejalan dengan Bery & Worokinasih, (2018) serta Az-zahrani et al., (2025) yang menyatakan bahwa pemilihan variabel input yang tepat sangat menentukan keberhasilan prediksi berbasis ANN. Selain itu, Chyan et al., (2024) dan Rustiyana et al., (2025) dan juga menunjukkan bahwa kombinasi beberapa jenis atribut lebih efektif dibandingkan penggunaan atribut tunggal. Dengan demikian, pernyataan masalah pertama dapat dijawab bahwa atribut data, khususnya data sentimen, berpengaruh signifikan dalam meningkatkan kinerja prediksi harga saham ADMR menggunakan model ANN.

Tabel 6. 1 Hasil performa model pada proses prediksi saham ADMR


Eksperimen	Epoch Berhenti	Waktu Konvergensi	MSE	MAE	R² Score	Akurasi (%)
BPNN-A1	125	4 ms/step	97,6276	57.589	0.9963	99.44
BPNN-A1-R	108	3 ms/step	116,6024	63.874	0.9956	99.39
BPNN-A1-L	174	3 ms/step	45,6602	35.210	0.9983	99.66
BPNN-A1-LR1	125	2 ms/step	97,6276	57.589	0.9963	99.44
BPNN-A1-LR3	125	2 ms/step	97,6276	57.589	0.9963	99.44
BPNN-A2	70	3 ms/step	152,9992	103.555	0.9943	99.01
BPNN-A2-R	63	2 ms/step	839,6472	246.212	0.9685	97.68
BPNN-B1	98	2 ms/step	122,5321	57.531	0.9960	99.47
BPNN-B1-L	61	2 ms/step	130,822	75.658	0.9958	99.31
BPNN-B2	79	2 ms/step	216,0978	124.498	0.9930	98.81
BPNN-C1	61	2 ms/step	221,3209	85.493	0.9903	99.14
BPNN-C2	93	2 ms/step	69,3157	60.734	0.9970	99.41
BPNN-D1	61	2 ms/step	237,4775	101.941	0.9909	99.02
BPNN-D2	61	2 ms/step	207,9012	93.837	0.9921	99.12
BPNN-TN	200	14ms/step	65,4084	5,4616	0,908	99,56
BPNN-TD	61	10ms/step	2005,188	39,9023	0,7426	95,5
BPNN-A1	60	3ms/step	2066,456	41,3153	0,9224	96,03
BPNN-A1-R	60	3ms/step	337,9253	15,324	0,9873	98,5
BPNN-A1-L	60	3ms/step	2341,187	43,9329	0,9121	95,73
BPNN-A1-LR1	60	3ms/step	2066,456	41,3153	0,9224	96,03
BPNN-A1-LR3	60	3ms/step	2066,456	41,3153	0,9224	96,03
BPNN-A2	60	2ms/step	1056,545	25,3962	0,9603	97,41
BPNN-A2-R	60	2ms/step	3187,875	49,0139	0,8803	95,04
BPNN-B1	60	2ms/step	1459,222	35,915	0,9527	96,62
BPNN-B1-L	60	2ms/step	2514,776	47,1858	0,9184	95,51
BPNN-B2	60	2ms/step	1934,844	33,643	0,9372	96,57
BPNN-C1	60	2ms/step	1547,607	35,2899	0,9323	96,42
BPNN-C2	60	2ms/step	797,5061	21,4761	0,9651	97,75
BPNN-D1	60	2ms/step	1816,893	38,8083	0,9308	96,15
BPNN-D2	60	2ms/step	1788,439	33,1491	0,9318	96,57
BPNN-TN	60	10ms/step	237,8985	13,4006	0,6655	98,92
BPNN-TD	61	11ms/step	2821,826	44,0234	0,6378	95,31

Analisis lebih lanjut berdasarkan karakteristik data menunjukkan bahwa sifat dan stabilitas data juga memengaruhi performa model BPNN. Pada model BPNNS berdasarkan karakteristik data, eksperimen BPNNS-TN menghasilkan MSE sebesar 65,4084 dan R^2 Score sebesar 0,908, yang menunjukkan kinerja prediksi yang relatif baik dan stabil. Sebaliknya, model BPNNS-TD memiliki MSE yang jauh lebih tinggi, yaitu 2005,188, dengan R^2 Score sebesar 0,7426, yang mengindikasikan kesulitan model dalam menangkap pola pada data dengan karakteristik yang lebih fluktuatif. Kondisi serupa juga terjadi pada model tanpa sentimen. BPNN-TN menunjukkan MSE sebesar 237,8985 dan R^2 Score sebesar 0,6655, sedangkan BPNN-TD menghasilkan MSE sebesar 2821,826 dan R^2 Score sebesar 0,6378. Nilai error yang tinggi pada data dengan karakteristik tertentu menunjukkan bahwa ANN cenderung lebih sulit melakukan pembelajaran optimal ketika data mengandung tingkat noise dan volatilitas yang tinggi. Hasil ini konsisten dengan temuan Qiu, Emerson, dan Xu (2016) yang menyatakan bahwa data dengan noise tinggi dapat memperlambat proses konvergensi dan menurunkan performa model ANN. Dengan demikian, karakteristik data merupakan faktor penting yang perlu diperhatikan selain pemilihan atribut input.

Menjawab pernyataan masalah kedua, hasil eksperimen menunjukkan bahwa skenario paling optimal untuk memprediksi harga saham ADMR adalah penggunaan model BPNN dengan atribut sentimen dan konfigurasi jaringan yang tepat. Model BPNNS-A1-L terbukti sebagai skenario terbaik karena menghasilkan kombinasi paling seimbang antara tingkat kesalahan yang rendah, nilai R^2 Score yang sangat tinggi, serta akurasi tertinggi dibandingkan eksperimen lainnya. Selain itu, model-model dengan data sentimen menunjukkan waktu konvergensi yang relatif singkat, yaitu berkisar antara 2–4 ms/step, meskipun jumlah epoch berhenti bervariasi. Hal ini menunjukkan bahwa atribut sentimen membantu jaringan saraf mengenali pola penting lebih cepat, sehingga proses pembelajaran menjadi lebih efisien dan stabil. Sebaliknya, meskipun beberapa model tanpa sentimen memiliki waktu konvergensi yang cepat, performa prediksinya tetap lebih rendah akibat keterbatasan informasi input.

Temuan ini mendukung pernyataan Patel et al. (2015) bahwa kombinasi atribut yang representatif mampu meningkatkan efektivitas model prediksi, serta (Tribuana et al., 2025) yang menekankan pentingnya efisiensi konvergensi dalam evaluasi kinerja ANN. Dengan demikian, dapat disimpulkan bahwa skenario optimal dalam penelitian ini adalah penggunaan model BPNN

berbasis data sentimen dengan karakteristik data yang relatif stabil. Secara keseluruhan, hasil penelitian ini menegaskan bahwa keberhasilan prediksi harga saham ADMR menggunakan ANN sangat ditentukan oleh pemilihan atribut data dan karakteristik data yang digunakan. Atribut sentimen terbukti meningkatkan akurasi, menurunkan tingkat kesalahan, serta mempercepat konvergensi model. Oleh karena itu, tahapan praproses data dan seleksi atribut merupakan fondasi utama dalam pengembangan model prediksi harga saham berbasis ANN yang andal dan aplikatif.



Gambar 6. 1 Perbandingan waktu konvergensi BPNN pada dua skenario

Pada skenario kedua, model dilatih tanpa menggunakan atribut sentimen, sehingga seluruh proses pembelajaran hanya bergantung pada data historis numerik. Berdasarkan ringkasan hasil eksperimen, performa model pada skenario ini secara konsisten lebih rendah dibandingkan skenario pertama yang memanfaatkan data sentimen. Akurasi model berada pada rentang 95,04% hingga 98,50%, dengan model terbaik dicapai oleh BPNN-A1-R yang menghasilkan akurasi sebesar 98,50% dan R^2 Score sebesar 0,9873. Sementara itu, model BPNN-C2 memperoleh akurasi sebesar 97,75% dengan R^2 Score sebesar 0,9651, yang masih berada di bawah capaian terbaik model dengan sentimen.

Variasi performa antar-eksperimen pada skenario kedua terlihat lebih jelas dibandingkan skenario pertama. Sebagai contoh, BPNN-A1 hanya mencapai akurasi sebesar 96,03%, sedangkan BPNN-A2-R turun hingga 95,04%. Perbedaan ini menunjukkan bahwa tanpa informasi sentimen, jaringan saraf harus sepenuhnya mengandalkan pola historis harga, yang tidak selalu mampu merepresentasikan dinamika psikologis dan ekspektasi pasar secara komprehensif. Akibatnya,


model menjadi lebih sensitif terhadap variasi arsitektur dan konfigurasi pelatihan. Meskipun waktu konvergensi pada skenario kedua relatif cepat dan berada pada rentang 2–3 ms/step, kecepatan konvergensi tersebut tidak secara otomatis berbanding lurus dengan kualitas prediksi. Hal ini terlihat dari beberapa model yang mencapai konvergensi cepat namun menghasilkan nilai MSE yang tinggi, seperti BPNN-A2-R dengan MSE sebesar 3187,875. Temuan ini menunjukkan bahwa konvergensi cepat tanpa atribut input yang informatif tidak menjamin model mampu mempelajari pola harga saham secara optimal.

Fenomena menurunnya performa model tanpa data sentimen sejalan dengan temuan Zhang, Patuwo, dan Hu (1998) yang menekankan bahwa keberhasilan prediksi menggunakan ANN lebih ditentukan oleh relevansi atribut input dibandingkan sekadar peningkatan kompleksitas arsitektur jaringan. Dalam penelitian ini, meskipun beberapa model tanpa sentimen menggunakan arsitektur yang lebih dalam, seperti BPNN-D2, performanya tetap relatif rendah dengan akurasi sebesar 96,57% dan R^2 Score sebesar 0,9318. Temuan ini juga konsisten dengan Qiu, Emerson, dan Xu (2016) yang menyatakan bahwa peningkatan kedalaman jaringan saraf tidak selalu menghasilkan performa yang lebih baik apabila data input mengandung noise atau tidak cukup representatif. Pada kondisi tersebut, model justru berisiko mengalami overfitting karena kapasitas jaringan yang besar tidak diimbangi oleh kualitas informasi input yang memadai. Hal ini tercermin pada tingginya nilai MSE pada beberapa model tanpa sentimen, meskipun arsitekturnya lebih kompleks.

Kesenjangan performa antara BPNN-C2 dan BPNN-D2 semakin menegaskan bahwa kualitas atribut input memiliki pengaruh yang lebih dominan dibandingkan sekadar memperbesar kapasitas jaringan. Penambahan hidden layer memang meningkatkan kemampuan model untuk mempelajari hubungan non-linear, namun tanpa atribut yang relevan, kapasitas tersebut tidak dimanfaatkan secara optimal. Akibatnya, model dengan arsitektur lebih dalam tidak selalu mampu menghasilkan prediksi yang lebih akurat. Kondisi ini selaras dengan prinsip dasar machine learning, yaitu garbage in, garbage out (Sukendro et al., 2024), yang menyatakan bahwa kualitas output model sepenuhnya bergantung pada kualitas input data. Dalam konteks penelitian ini, ketiadaan data sentimen menyebabkan informasi penting terkait dinamika pasar tidak terwakili, sehingga menurunkan kemampuan ANN dalam melakukan prediksi harga saham ADMR secara presisi. Selain itu, ANN dikenal sangat sensitif terhadap kualitas data input. Huang et al. (2005)

menegaskan bahwa atribut yang tidak relevan dapat memperbesar risiko overfitting dan menurunkan akurasi prediksi ANN. Temuan tersebut konsisten dengan hasil penelitian ini, di mana model tanpa sentimen menunjukkan fluktuasi performa yang lebih besar dan tingkat kesalahan yang lebih tinggi dibandingkan model dengan sentimen.

Berdasarkan keseluruhan hasil eksperimen, dapat disintesis bahwa atribut data memiliki pengaruh yang signifikan terhadap keberhasilan prediksi harga saham ADMR menggunakan ANN. Penambahan data sentimen terbukti mampu menurunkan nilai MSE, meningkatkan R^2 Score, serta menghasilkan akurasi yang lebih tinggi dan stabil. Kombinasi atribut numerik dan sentimen memungkinkan model menangkap hubungan non-linear tersembunyi yang tidak dapat diidentifikasi hanya dari data historis harga. Oleh karena itu, jawaban atas pernyataan masalah pertama adalah bahwa atribut data, khususnya data sentimen, berperan krusial dalam meningkatkan kinerja prediksi harga saham ADMR berbasis ANN. Strategi utama dalam pemodelan prediksi bukanlah semata-mata memperbesar kapasitas jaringan, melainkan memastikan bahwa atribut input yang digunakan benar-benar merepresentasikan dinamika pasar secara akurat.



Gambar 6. 2 Perbandingan akurasi BPNN pada dua skenario


Penelitian ini merancang dua skenario utama dengan variasi arsitektur, yaitu 7-32-1 dan 7-32-16-1 pada skenario pertama (dengan sentimen), serta 6-32-1 dan 6-32-16-1 pada skenario kedua (tanpa sentimen). Perancangan ini bertujuan untuk menguji apakah penambahan atribut

sentimen dan peningkatan kompleksitas arsitektur memberikan dampak signifikan terhadap performa prediksi.

Hasil eksperimen menunjukkan bahwa skenario pertama merupakan skenario paling optimal. Model-model pada skenario ini secara konsisten menghasilkan akurasi di atas 99%, dengan performa terbaik dicapai oleh BPNNS-A1-L yang memperoleh akurasi sebesar 99,66% dan R^2 Score sebesar 0,9983. Hasil ini membuktikan bahwa arsitektur yang relatif sederhana dapat menghasilkan performa sangat tinggi apabila dipadukan dengan atribut input yang relevan.

Temuan ini sejalan dengan Zhang dan Zhou (2021) serta Dewi et al. (2022) yang menegaskan bahwa pemilihan atribut input memiliki pengaruh yang lebih besar dibandingkan sekadar memperdalam arsitektur jaringan. Dengan kata lain, kecocokan data input merupakan faktor kunci dalam keberhasilan prediksi harga saham menggunakan ANN. Namun demikian, meskipun skenario pertama menunjukkan performa yang sangat tinggi, variasi performa antar-eksperimen tetap perlu diperhatikan. Beberapa model, seperti BPNNS-B2, menunjukkan akurasi yang lebih rendah dibandingkan model terbaik, yaitu 98,81%. Hal ini mengindikasikan bahwa model dengan arsitektur sederhana masih rentan terhadap variasi proses pelatihan, seperti inisialisasi bobot dan sensitivitas terhadap atribut input, sebagaimana dikemukakan oleh Suryanto dan Nugroho (2020) serta Kim dan Kang (2021).

Secara keseluruhan, skenario pertama dengan penambahan data sentimen merupakan skenario paling optimal dalam memprediksi harga saham ADMR. Temuan ini menegaskan bahwa efisiensi dan relevansi atribut data jauh lebih penting dibandingkan peningkatan kompleksitas arsitektur jaringan, serta mendukung prinsip bahwa model yang tepat guna lebih efektif daripada model yang terlalu kompleks.



Gambar 6. 3 Perbandingan performa terbaik antar eksperimen

Pada skenario kedua (model BPNN tanpa data sentimen), model terbaik yang diperoleh berdasarkan hasil pengujian adalah BPNN-A1-R dengan tingkat akurasi sebesar 98,50% dan nilai R^2 Score 0,9873. Model BPNN-C2 berada pada tingkat performa berikutnya dengan akurasi 97,75%. Jika dibandingkan dengan skenario pertama yang menggunakan data sentimen, capaian akurasi ini relatif lebih rendah, mengindikasikan bahwa penghilangan atribut sentimen berdampak pada menurunnya kemampuan model dalam menangkap pola pergerakan harga saham ADMR. Namun demikian, perbedaan akurasi tersebut masih berada dalam rentang yang wajar dan menunjukkan bahwa model tanpa sentimen tetap memiliki kemampuan prediksi yang cukup baik.

Fenomena ini menunjukkan bahwa akurasi tertinggi bukan satu-satunya indikator keberhasilan model prediksi. Pada skenario kedua, meskipun nilai akurasi tidak setinggi skenario pertama, sebagian besar model menunjukkan performa yang relatif stabil dengan rentang akurasi 95,04% hingga 98,50%. Stabilitas ini menjadi aspek penting, terutama apabila model ditujukan untuk implementasi nyata pada pasar saham yang sangat dinamis (Kalsum *et al.*, 2023). Model dengan performa yang konsisten lebih mudah dipercaya sebagai alat bantu pengambilan keputusan

karena risiko fluktuasi hasil prediksi dapat diminimalkan (Kurniati & Sidik, 2023). Dengan demikian, skenario kedua memberikan gambaran bahwa keseimbangan antara akurasi dan konsistensi tetap dapat dicapai meskipun tanpa melibatkan data sentimen.

Jika ditinjau lebih lanjut, beberapa model dengan arsitektur berbeda, seperti BPNNS-A1 dan BPNNS-C2 pada skenario pertama, mampu mempertahankan akurasi di atas 99% dengan nilai R^2 Score yang tinggi. Capaian ini menunjukkan bahwa arsitektur jaringan yang lebih dalam, khususnya dengan penambahan hidden layer, memiliki keunggulan dalam menghadapi variasi data dan kondisi pelatihan yang berbeda. Lapisan tambahan memungkinkan jaringan melakukan abstraksi fitur yang lebih baik, sehingga kesalahan akibat variasi inisialisasi bobot atau pengaturan parameter dapat ditekan.


Kestabilan performa tersebut menjadi faktor penting dalam menilai keunggulan arsitektur dengan dua hidden layer dibandingkan arsitektur yang lebih sederhana. Dalam konteks praktis, investor atau analis pasar saham cenderung membutuhkan model yang tidak hanya mampu menghasilkan akurasi tinggi pada satu kondisi tertentu, tetapi juga konsisten dalam berbagai skenario pengujian (Dwisanny, 2024). Konsistensi prediksi ini memberikan tingkat kepercayaan yang lebih tinggi dan dapat dijadikan dasar pertimbangan dalam pengambilan keputusan investasi. Oleh karena itu, meskipun tidak selalu menghasilkan akurasi tertinggi, model dengan performa stabil dinilai lebih siap untuk diterapkan pada lingkungan nyata.

Meskipun arsitektur jaringan yang lebih dalam umumnya diasumsikan mampu menangkap pola yang lebih kompleks, hasil pengujian menunjukkan bahwa kelemahan tetap terlihat pada model BPNNS-A1 yang hanya mencapai akurasi 96,03%. Temuan ini memperkuat bahwa atribut input merupakan faktor yang sangat krusial dalam menentukan kinerja model, bahkan ketika arsitektur jaringan telah dibuat lebih kompleks. Hasil ini sejalan dengan penelitian Zhou et al. (2020) yang menyatakan bahwa kualitas dan relevansi fitur memiliki pengaruh yang lebih besar dibandingkan kompleksitas arsitektur dalam prediksi keuangan.

Jika dibandingkan langsung dengan skenario pertama, terlihat bahwa pendekatan dengan penambahan atribut sentimen mampu menghasilkan akurasi yang lebih tinggi, seperti yang ditunjukkan oleh BPNNS-B1 dengan akurasi 99,47%. Namun demikian, keunggulan utama

skenario kedua terletak pada konsistensinya, di mana sebagian besar model tetap berada pada kisaran akurasi di atas 95%. Konsistensi ini menjadi penting karena dalam aplikasi nyata, kestabilan performa sering kali lebih dibutuhkan dibandingkan satu eksperimen dengan hasil yang sangat tinggi. Pandangan ini sejalan dengan temuan Sahi & Galib (2025) yang menekankan bahwa model yang stabil dan mudah direplikasi memiliki nilai lebih tinggi untuk implementasi praktis.

Secara keseluruhan, hasil pengujian ini menunjukkan bahwa pemilihan skenario optimal sangat bergantung pada kebutuhan praktis yang ingin dicapai. Jika tujuan utama adalah memperoleh akurasi maksimum, maka skenario pertama dengan model BPNNS, khususnya BPNNS-A1-L, merupakan pilihan paling optimal. Namun, jika tujuan difokuskan pada kestabilan performa, maka skenario kedua tetap layak dipertimbangkan. Dengan demikian, dapat disimpulkan bahwa atribut data berpengaruh signifikan terhadap prediksi harga saham ADMR, dan skenario optimal ditentukan oleh keseimbangan antara akurasi dan konsistensi sesuai kebutuhan penggunaan model.



Gambar 6. 4 Perbandingan performa terbaik skenario Pertama & Kedua

Perbandingan kedua skenario memperlihatkan bahwa dalam pemodelan ANN, kedalaman arsitektur berkontribusi terhadap stabilitas performa, meskipun tidak selalu menghasilkan akurasi tertinggi. Berdasarkan hasil pengujian, model dengan konfigurasi arsitektur

yang lebih dalam pada skenario kedua (tanpa sentimen) cenderung menghasilkan akurasi yang berada pada rentang relatif sempit, yaitu 95,04% hingga 98,50%. Sebaliknya, pada skenario pertama (dengan sentimen), variasi arsitektur menghasilkan rentang akurasi yang lebih lebar namun mampu mencapai nilai maksimum hingga 99,66%. Pola ini menunjukkan bahwa peningkatan kedalaman jaringan membantu menjaga konsistensi performa, tetapi akurasi mutlak tetap sangat dipengaruhi oleh atribut data yang digunakan.

Lebih jauh, hasil pengujian menunjukkan bahwa stabilitas performa pada skenario kedua tidak selalu menjamin reliabilitas absolut. Hal ini terlihat pada model BPNN-A1, yang meskipun menggunakan arsitektur ANN yang sama dengan eksperimen lain, hanya mampu mencapai akurasi 96,03%, terendah di antara seluruh konfigurasi tanpa sentimen. Temuan ini menegaskan bahwa kedalaman jaringan memang berperan dalam menjaga konsistensi hasil, namun kualitas atribut input dan pengaturan parameter pelatihan tetap menjadi faktor utama dalam menentukan keberhasilan model. Dengan demikian, terdapat trade-off yang jelas antara stabilitas dan akurasi yang perlu dipertimbangkan secara cermat dalam perancangan model.

Oleh karena itu, dalam konteks penerapan praktis, skenario pertama lebih disarankan karena terbukti mampu menghasilkan akurasi yang lebih tinggi dan lebih adaptif terhadap dinamika data saham. Hal ini ditunjukkan oleh eksperimen BPNN-B1 yang mencapai akurasi 99,47%, serta BPNN-A1-L yang mencatat akurasi tertinggi sebesar 99,66%. Capaian ini menunjukkan bahwa dengan atribut input yang relevan, khususnya penambahan data sentimen, arsitektur yang relatif sederhana pun mampu menghasilkan prediksi yang sangat akurat. Kondisi ini menegaskan bahwa kompleksitas model tidak selalu menjadi prasyarat utama untuk memperoleh performa optimal.

Selain itu, keberhasilan skenario pertama juga memperkuat prinsip parsimony dalam machine learning, yaitu bahwa model yang lebih sederhana dapat memberikan hasil yang unggul selama data yang digunakan berkualitas dan sesuai dengan tujuan analisis (Fahmiyah, 2018). Dalam konteks prediksi harga saham ADMR, hasil ini memberikan implikasi praktis bahwa peningkatan kualitas atribut input, khususnya melalui integrasi data sentimen, lebih berdampak dibandingkan sekadar menambah kompleksitas arsitektur jaringan. Dengan demikian, pendekatan

yang efisien dan tepat sasaran menjadi lebih relevan untuk kebutuhan pengambilan keputusan yang cepat dan akurat di sektor keuangan.

Sementara itu, skenario kedua tetap memiliki relevansi, terutama apabila fokus penelitian diarahkan pada konsistensi performa antar-model. Namun demikian, hasil pengujian menunjukkan bahwa risiko penurunan performa masih cukup signifikan apabila atribut input yang digunakan kurang optimal. Model BPNN-A1 kembali menjadi contoh, di mana akurasi hanya mencapai 96,03%, meskipun menggunakan arsitektur ANN yang sama dengan eksperimen lain. Temuan ini menunjukkan bahwa kedalaman arsitektur tidak secara otomatis melindungi model dari dampak negatif pemilihan atribut input yang kurang representatif.

Dengan demikian, penggunaan skenario kedua dalam praktik memerlukan perhatian yang lebih besar terhadap pemilihan variabel input, pengaturan hyperparameter, serta strategi pelatihan yang tepat. Tanpa pengendalian yang memadai, model berisiko menghasilkan performa yang tidak konsisten atau di bawah ekspektasi, sebagaimana tercermin pada beberapa eksperimen tanpa sentimen. Oleh karena itu, dalam kondisi pasar saham yang sarat ketidakpastian, skenario pertama dinilai lebih aman dan andal, sedangkan skenario kedua lebih sesuai digunakan secara selektif dengan pengawasan ketat terhadap kualitas data dan proses pelatihan.

Temuan ini sejalan dengan penelitian sebelumnya yang menyatakan bahwa ANN dengan dua hidden layer memiliki kemampuan lebih baik dalam menangkap hubungan non-linear yang kompleks, sehingga menghasilkan prediksi yang lebih stabil. Studi Zhang et al. (2020) menunjukkan bahwa penambahan lapisan tersembunyi mampu memperkaya representasi fitur dan mengurangi sensitivitas model terhadap fluktuasi data. Temuan serupa juga dilaporkan oleh Rahman & Sutrisno (2022) pada prediksi pasar valuta asing, di mana ANN dengan dua hidden layer menghasilkan variabilitas prediksi yang lebih rendah dibandingkan model satu hidden layer.

Namun demikian, penelitian-penelitian tersebut juga menegaskan bahwa peningkatan kompleksitas arsitektur harus diimbangi dengan kualitas data dan strategi optimisasi yang memadai. Tanpa dukungan tersebut, stabilitas justru dapat menurun, sebagaimana tercermin pada hasil eksperimen BPNN-A1. Oleh karena itu, penelitian lanjutan direkomendasikan untuk mengombinasikan pemilihan atribut input yang optimal dengan teknik optimisasi lanjutan, seperti

Bayesian optimization atau adaptive learning rate, guna menjaga keseimbangan antara akurasi dan konsistensi prediksi dalam penerapan ANN pada data saham.

6.2 Integrasi Sains dan Islam

Penggunaan model Artificial Neural Network (ANN) dalam memprediksi harga saham menunjukkan bagaimana manusia memanfaatkan kemampuan intelektual dan teknologi untuk memahami fenomena yang kompleks. Namun, dalam perspektif Islam, upaya prediksi ini tetap berada dalam batas-batas kemampuan manusia yang terbatas dan tidak dapat dipisahkan dari ketentuan Allah SWT. ANN dapat mengolah data dalam jumlah besar dan mendeteksi pola tersembunyi, tetapi tetap tidak mampu memastikan hasil secara absolut. Prinsip ini sejalan dengan ajaran Islam bahwa manusia diperintahkan untuk berikhtiar semaksimal mungkin, sementara hasil akhir tetap menjadi hak prerogatif Allah.

Konsep prediksi dalam Islam telah digambarkan dalam kisah Nabi Yusuf a.s. ketika menafsirkan mimpi Raja Mesir tentang tujuh sapi gemuk yang dimakan tujuh sapi kurus. Allah berfirman dalam QS. Yusuf ayat 43–44 mengenai mimpi tersebut:

وَقَالَ الْمَلِكُ إِنِّي أَرَى سَبْعَ بَقَرَاتٍ سِمَانٍ يَأْكُلُهُنَّ سَبْعٌ عِجَافٌ وَسَبْعَ سُنبُلَاتٍ خُضْرٍ وَأُخَرَ يَابِسَاتٍ يَا أَيُّهَا الْمَلَأُ أَفْتُونِي فِي رُؤْيَايَ إِن كُنْتُمْ لِلرُّؤْيَا تَعْبُرُونَ (٤٣) قَالُوا أَضْغَاثُ أَحْلَامٍ وَمَا نَحْنُ بِتَأْوِيلِ الْأَحْلَامِ بِعَالَمِينَ (٤٤)

Artinya: "Raja berkata, 'Sesungguhnya aku bermimpi melihat tujuh ekor sapi betina yang gemuk dimakan oleh tujuh ekor sapi betina yang kurus, dan tujuh bulir (gandum) yang hijau serta tujuh bulir lainnya yang kering. Wahai para pembesar! Jelaskanlah kepadaku tentang mimpiku itu jika kamu dapat menafsirkan mimpi.' Mereka berkata, 'Itu adalah mimpi-mimpi yang kosong, dan kami tidak mengetahui takwil mimpi seperti itu.'"

Ibnu Katsir dalam Tafsir al-Qur'an al-'Azhim (ringkasan Fathul Karim) menjelaskan bahwa mimpi raja Mesir pada ayat Yusuf 43-44 merupakan takdir Allah SWT yang menjadi penyebab keluarnya Nabi Yusuf AS dari penjara dalam keadaan mulia dan terhormat. Raja kaget melihat tujuh sapi gemuk dimakan tujuh sapi kurus (melambangkan tujuh tahun subur diikuti paceklik), serta tujuh bulir hijau dan kering; ia mengumpulkan tukang ramal, paranormal, dan pembesar, tapi mereka menolaknya sebagai "aḍghāthu ahlāmin" (mimpi-mimpi kosong) dan mengaku tidak tahu ta'wīlnya.

Ayat ini menunjukkan bahwa Allah memberikan kepada manusia kemampuan untuk membaca tanda-tanda dan memprediksi kejadian di masa depan, namun kemampuan tersebut bersumber dari petunjuk-Nya. Kisah ini mengajarkan bahwa analisis dan perencanaan berdasarkan prediksi adalah bagian dari usaha manusia, tetapi tetap harus dilandasi kesadaran bahwa ilmu tersebut adalah karunia Allah.

Kemampuan ANN dalam memprediksi pola pasar dapat dianalogikan dengan hikmah yang diajarkan dalam kisah Nabi Yusuf. Prediksi yang akurat bukan sekadar hasil kemampuan teknis, tetapi juga harus ditempatkan dalam kerangka etika, tanggung jawab, dan kesadaran bahwa ketidakpastian tetap ada. Seperti halnya Nabi Yusuf mengajarkan strategi penyimpanan pangan setelah memahami makna mimpi tersebut, penggunaan ANN dalam keuangan juga harus diarahkan untuk mendukung pengambilan keputusan yang bijaksana, bukan sekadar mengejar keuntungan jangka pendek.

Konsep prediksi juga dapat dikaitkan dengan kisah Nabi Musa a.s. dan Nabi Khidir a.s. dalam mencari keberadaan Nabi Khidir. Allah berfirman dalam QS. Al-Kahfi ayat 60 tentang perjalanan Nabi Musa:

وَإِذْ قَالَ مُوسَىٰ لِفَتَاهُ لَا أَبْرَحُ حَتَّىٰ أَبْلُغَ مَجْمَعَ الْبَحْرَيْنِ أَوْ أَمْضِيَ حُقُبًا (٦٠)

Artinya: *"Dan (ingatlah) ketika Musa berkata kepada muridnya: 'Aku tidak akan berhenti sebelum aku mencapai pertemuan dua lautan, atau aku akan berjalan sampai bertahun-tahun'."*

Ibnu Katsir dalam Tafsir al-Qur'an al-'Azhim menjelaskan ayat Al-Kahfi 60 sebagai awal kisah Nabi Musa AS yang bertekad mencari hamba saleh (Khidir AS) untuk menambah ilmunya, di mana Musa berkata kepada muridnya Yusu' bin Nun bahwa ia tidak akan berhenti hingga mencapai majma' al-bahrayn (pertemuan dua lautan), meski harus berjalan bertahun-tahun (ḥuqūbā). Kisah pencarian Nabi Musa terhadap Nabi Khidir dalam Surah Al-Kahfi menghadirkan suatu model pencarian berbasis indikator yang dapat dipahami secara ilmiah dan naratif. Dalam ayat tersebut, dua variabel utama ditetapkan: lokasi geospasial berupa majma' al-bahrayn (pertemuan dua lautan) dan indikator peristiwa berupa hilangnya ikan yang dibawa sebagai bekal. Secara ilmiah, pola ini menyerupai pendekatan data-driven search, yaitu pencarian melalui kombinasi data lingkungan dan sinyal peristiwa. Nabi Musa tidak memiliki informasi langsung

mengenai keberadaan Khidir, tetapi ia diberi parameter awal (lokasi geografis) sekaligus tanda penentu (hilangnya ikan), sehingga proses pencarian menjadi sistematis.

Kisah pencarian Nabi Musa terhadap Nabi Khidir dalam Surah Al-Kahfi menghadirkan suatu model pencarian berbasis indikator yang dapat dipahami secara ilmiah dan naratif. Dalam ayat tersebut, dua variabel utama ditetapkan: lokasi geospasial berupa *majma' al-bahrayn* (pertemuan dua lautan) dan indikator peristiwa berupa hilangnya ikan yang dibawa sebagai bekal. Secara ilmiah, pola ini menyerupai pendekatan data-driven search, yaitu pencarian melalui kombinasi data lingkungan dan sinyal peristiwa. Nabi Musa tidak memiliki informasi langsung mengenai keberadaan Khidir, tetapi ia diberi parameter awal (lokasi geografis) sekaligus tanda penentu (hilangnya ikan), sehingga proses pencarian menjadi sistematis.

Secara naratif, perjalanan Musa menggambarkan dinamika pencarian berbasis observasi lapangan. Musa dan pemuda pendampingnya menjelajahi wilayah yang luas tanpa kepastian, namun tetap berpegang pada dua indikator yang telah disebutkan. Hilangnya ikan di titik tertentu berfungsi sebagai trigger event yang menandai lokasi yang tepat, mirip dengan mekanisme ilmiah ketika sebuah fenomena tak terlihat dideteksi melalui perubahan pada variabel yang dapat diamati. Dengan demikian, peristiwa hilangnya ikan bukan sekadar kejadian supranatural, melainkan instrumen penunjuk yang mengarahkan Musa menuju tempat pertemuan dengan sosok berilmu yang ia cari.

Penafsirannya menunjukkan bahwa Al-Qur'an memperkenalkan konsep bahwa pengetahuan dapat ditemukan melalui pengamatan terhadap tanda-tanda empiris, dan bahwa petunjuk ilahi sering hadir dalam bentuk variabel atau fenomena yang harus dianalisis. Kisah ini menggambarkan bahwa pencarian sesuatu yang tidak kasat mata—baik sosok Khidir maupun sebuah kebenaran—bergantung pada kemampuan membaca tanda, menghubungkan data, dan menarik kesimpulan dari perubahan yang terjadi di lingkungan. Dengan demikian, Nabi Musa menjadi contoh tokoh pencari ilmu yang menggunakan indikator, observasi, dan analisis, sehingga pencariannya bersifat terstruktur meski tujuannya bersifat ghaib. Ini menghadirkan sintesis antara narasi spiritual dan kerangka berpikir ilmiah yang menekankan ketekunan, interpretasi data, dan kepekaan terhadap tanda-tanda di sekitar.

BAB VII

KESIMPULAN

7.1 Kesimpulan

Berdasarkan hasil pengujian dan analisis terhadap penerapan model Artificial Neural Network (ANN) dalam memprediksi harga saham ADMR, dapat ditarik beberapa kesimpulan utama yang secara langsung menjawab rumusan masalah penelitian ini:

- a. Pertama, atribut data terbukti memiliki pengaruh yang sangat signifikan terhadap akurasi prediksi harga saham ADMR. Hasil eksperimen menunjukkan bahwa model ANN yang menggunakan kombinasi data historis harga dan data sentimen (skenario dengan sentimen) secara konsisten menghasilkan nilai akurasi yang lebih tinggi dibandingkan model yang hanya menggunakan data historis harga. Hal ini tercermin pada model BPNNS-A1-L, yang mampu mencapai akurasi tertinggi sebesar 99,66%, dengan nilai kesalahan yang relatif rendah. Penambahan atribut sentimen mampu memperkaya representasi informasi yang dipelajari oleh jaringan saraf, sehingga model lebih responsif terhadap dinamika pasar yang tidak sepenuhnya tercermin dalam data numerik historis. Temuan ini menegaskan bahwa kualitas dan relevansi atribut input lebih berpengaruh terhadap performa model dibandingkan sekadar kompleksitas arsitektur ANN.
- b. Kedua, skenario yang paling optimal untuk memprediksi harga saham ADMR berdasarkan model ANN adalah skenario dengan penambahan data sentimen. Skenario ini tidak hanya mampu mencapai akurasi tertinggi, tetapi juga menunjukkan kemampuan adaptasi yang lebih baik terhadap fluktuasi data. Pada skenario ini, model BPNNS-A1-L kembali menunjukkan performa paling optimal dengan nilai R^2 sebesar 0,9983 dan akurasi 99,66%, bahkan dengan arsitektur ANN yang relatif sederhana. Sebaliknya, skenario tanpa sentimen cenderung menghasilkan akurasi yang lebih rendah, dengan capaian terbaik berada di bawah skenario bersentimen. Oleh karena itu,

untuk kebutuhan prediksi yang menuntut ketepatan tinggi, skenario dengan sentimen dinilai lebih andal dan aplikatif.

- c. Selain itu, ditinjau dari karakteristik data, data harga saham ADMR memiliki sifat non-linear, fluktuatif, dan dipengaruhi oleh faktor eksternal di luar pergerakan historis harga. Karakteristik ini menyebabkan model ANN memerlukan atribut tambahan yang mampu menangkap konteks pasar secara lebih luas. Data sentimen berperan sebagai representasi faktor eksternal tersebut, sehingga membantu model mengenali pola tersembunyi yang tidak dapat dijelaskan oleh data numerik semata. Tanpa atribut yang mencerminkan kondisi psikologis dan persepsi pasar, model berpotensi kehilangan informasi penting yang berdampak langsung pada akurasi prediksi.

7.2 Keterbatasan dan saran

Penelitian ini memiliki beberapa keterbatasan yang perlu diperhatikan dalam menginterpretasikan hasil yang diperoleh sekaligus menjadi dasar bagi pengembangan penelitian selanjutnya. Pertama, data sentimen yang digunakan masih bersumber dari teks opini publik secara umum, sehingga belum sepenuhnya merepresentasikan keseluruhan persepsi pasar, khususnya sentimen dari pelaku institusional atau investor besar yang memiliki pengaruh signifikan terhadap pergerakan harga saham. Kondisi ini berpotensi menyebabkan informasi sentimen yang digunakan belum sepenuhnya mencerminkan tekanan pasar yang sebenarnya. Oleh karena itu, penelitian lanjutan disarankan untuk mengembangkan sumber data sentimen yang lebih beragam, seperti laporan analis, berita keuangan resmi, serta media sosial yang terverifikasi, agar informasi sentimen yang digunakan menjadi lebih komprehensif dan representatif terhadap kondisi pasar.

Kedua, ruang lingkup data pada penelitian ini terbatas pada satu emiten, yaitu saham ADMR, sehingga hasil yang diperoleh belum dapat digeneralisasi secara luas untuk saham lain dengan karakteristik sektor, tingkat volatilitas, dan likuiditas yang berbeda. Pola hubungan antara data historis harga dan sentimen pasar pada saham ADMR belum tentu sama pada saham lain dengan kapitalisasi maupun sektor industri yang berbeda. Oleh sebab itu, penelitian selanjutnya disarankan untuk memperluas objek penelitian dengan melibatkan lebih banyak saham dari berbagai sektor atau indeks pasar, sehingga tingkat generalisasi model prediksi dapat diuji dan kontribusi penelitian menjadi lebih luas.

Ketiga, meskipun model ANN yang digunakan telah menunjukkan performa yang sangat baik, pendekatan pelatihan yang diterapkan masih bersifat konvensional dengan pengaturan hyperparameter yang terbatas. Beberapa model menunjukkan sensitivitas terhadap konfigurasi parameter dan pemilihan atribut input, yang berpotensi menimbulkan risiko overfitting apabila model diterapkan pada kondisi data yang berbeda. Untuk mengatasi keterbatasan tersebut, penelitian lanjutan disarankan untuk menerapkan teknik optimisasi hyperparameter yang lebih lanjut, seperti Bayesian optimization, grid search, atau adaptive learning rate, serta mengombinasikan ANN dengan pendekatan lain seperti model hibrida atau ensemble. Pendekatan ini diharapkan mampu meningkatkan stabilitas model, mengurangi risiko overfitting, dan mempertahankan akurasi prediksi pada berbagai kondisi data.

REFERENSI

- Adriyendi, A. (2025). *ARTIFICIAL INTELLIGENCE DENGAN MODEL DISKRIMINATIF DAN MODEL GENERATIF (Pendekatan Saintifik Populer pada Riset Kolaboratif)*.
- Agatonovic-Kustrin, S., & Beresford, R. (2000). Basic concepts of artificial neural network (ANN) modeling and its application in pharmaceutical research. *Journal of Pharmaceutical and Biomedical Analysis*, 22(5), 717–727.
- Amalya, N. T. (2018). Pengaruh return on asset, return on equity, net profit margin dan debt to equity ratio terhadap harga saham. *Jurnal Sekuritas*, 1(3), 157–181.
- Anjeliana, A. (2022). *Penilaian Tingkat Kinerja Keuangan dengan Menggunakan Analisis Rasio Keuangan pada Perusahaan PT. Adaro Energy Tbk di Bursa Efek Indonesia Tahun 2018-2022*. Universitas Muhammadiyah Berau.
- Aqila, S., Rabi'atul, A., Annamma, K., Teh Halimaton, R., & Hamidah, H. (2019). Reflection of new graduate nurses on the transition program conducted in the selected Malaysian private hospitals. *Journal of Patient Care*, 5(144), 2.
- Asenahabi, B. M. (2019). Basics of research design: A guide to selecting appropriate research design. *International Journal of Contemporary Applied Researches*, 6(5), 76–89.
- Az-zahrani, N. S. N., Eloji, H. K. A., Salim, F., Ramadhani, A.-Z. A., Meysyanti, C., & Purwantiningsih, L. N. A. (2025). *Python untuk Analisis Data*. SIEGA Publisher.
- Bailey, R. E. (2005). *The economics of financial markets*. Cambridge University Press.
- Ballings, M., Van den Poel, D., Hespeels, N., & Gryp, R. (2015). Evaluating multiple classifiers for stock price direction prediction. *Expert Systems with Applications*, 42(20), 7046–7056.
- Bery, D., & Worokinasih, S. (2018). Pengaruh Indeks Harga Saham Global Terhadap Indeks Harga Saham Gabungan (IHSG). *Jurnal Administrasi Bisnis*, 64(1), 126–135.
- Cahyaningtyas, K., Maulida, S. N., Sari, L., & Ahman, A. (n.d.). EXPLORATION OF ORDINAL TO INTERVAL DATA TRANSFORMATION IN PSYCHOLOGICAL DATA PROCESSING. *OPTIMA: Journal Of Guidance and Counseling*, 5(1), 27–42.
- Chiu, C. J., Harris, R. D. F., Stoja, E., & Chin, M. (2018). Financial market volatility, macroeconomic fundamentals and investor sentiment. *Journal of Banking & Finance*, 92, 130–145.
- Chong, E., Han, C., & Park, F. C. (2017). Deep learning networks for stock market analysis and prediction: Methodology, data representations, and case studies. *Expert Systems with Applications*, 83, 187–205.
- Chyan, P., Gustiana, Z., Arni, S., Yasir, A., Husain, H., Dermawan, B. A., Oktarino, A., Indrayana, I. P. T., Siregar, A. M., & Gormantara, A. (2024). Pengantar Data Science: Mengambil Keputusan Berdasarkan Data. *Penerbit Mifandi Mandiri Digital*, 1(01).

- Destina Paningrum, S. E. (2022). *Buku referensi investasi pasar modal*. Lembaga Chakra Brahmana Lentera.
- Dwisanny, A. A. (2024). *Model Prediksi Inflasi Berbasis Lstm (Long Short-Term Memory) Neural Network Dan Analisis Faktor-Faktor Yang Mempengaruhinya*. Universitas Komputer Indonesia.
- Fagustina, A. (2014). *Pengaruh Fungsi Pembelajaran Terhadap Kinerja Pelatihan Jaringan Syaraf Tiruan Backpropagation Studi Kasus: Indeks Harga Saham Gabungan di Bursa Efek Indonesia*.
- Fahmiah, I. (2018). *Model Generalized Autoregressive Conditional Heteroscedasticity dengan Optimasi Algoritma Genetika untuk Peramalan Kecepatan Angin Rata-Rata Harian di Juanda Surabaya*. Institut Teknologi Sepuluh Nopember.
- Fairuza, M. Z. (2021). *PENGARUH EFEKTIVITAS PENERIMAAN PAJAK DAERAH DAN RETRIBUSI DAERAH TERHADAP EFEKTIVITAS PENDAPATAN ASLI DAERAH (Sensus Pada Pemerintah Kabupaten/Kota di Provinsi Jawa Barat Tahun 2016-2020)*. Universitas Siliwangi.
- Fausett, L. (1994). *Fundamentals of Neural Networks: Architectures, Applications and Algorithms*. Prentice-Hall International, Inc.
- Fischer, T., & Krauss, C. (2018). Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*, 270(2), 654–669.
- Gupta, P., Talreja, S., Jadon, R. S., & Gupta, S. K. (2022). Comparative Study of Machine Learning Models Implemented on Stock Market Datasets. *Proceedings of International Conference on Communication and Computational Technologies: ICCCT 2022*, 721–736.
- Ibn Kathīr, I. (n.d.). *Tafsīr al-Qur'ān al-'Azīm (Mukhtaṣar Faḥ al-Karīm)* (H. B. Yāsīn, Ring., Trans.). Ibnukatsironline.com. <http://www.ibnukatsironline.com/2015/05/tafsir-surat-yusuf-ayat-43-49.html>
- Ibn Kathīr, I. (n.d.). *Tafsīr al-Qur'ān al-'Azīm (Mukhtaṣar Faḥ al-Karīm)*. Ibnukatsironline.com. <http://www.ibnukatsironline.com/2015/06/tafsir-surat-al-kahfi-ayat-60-65.html>
- Izzati, H. (2025). Exploration of ordinal to interval data transformation in psychological data processing. *OPTIMA: Journal of Guidance and Counseling*, Universitas Pendidikan Indonesia.
- Juliandi, A., & Manurung, S. (2014). *Metodologi Penelitian Bisnis, Konsep dan Aplikasi: Sukses Menulis Skripsi & Tesis Mandiri*. Umsu Press.
- Kalsum, U., Bahtiar Efendi, S. E., MM, C. M. A., Zakiyudin Fikri, S. I. P., Astuti, M., & SE, M. M. (2023). *Optimalisasi Alokasi Sumber Daya Keuangan Strategi Maksimalkan Return*.
- Kurniati, A. B., & Sidik, W. A. (2023). Model Artificial Neural Networks (ANN) untuk Prediksi COVID-19 di Indonesia. *JST (Jurnal Sains Dan Teknologi)*, 12(3), 833–844.

- Laporan Perdagangan Saham Harian Tahun 2025. (2025). In *Bursa Efek Indonesia*. <https://www.idx.co.id>
- Lim, W. T., Wang, L., Wang, Y., & Chang, Q. (2016). Housing price prediction using neural networks. *2016 12th International Conference on Natural Computation, Fuzzy Systems and Knowledge Discovery (ICNC-FSKD)*, 518–522.
- Liu, F., Guo, S., Xing, Q., Sha, X., Chen, Y., Jin, Y., Zheng, Q., & Yu, C. (2024). Application of an ANN and LSTM-based Ensemble Model for Stock Market Prediction. *ArXiv Preprint ArXiv:2410.20253*.
- Liu, Q., Hu, Y., & Liu, H. (2024). Ensemble Forecasting of Stock Prices using Multidimensional Grey Model and ATT-LSTM with Multi-source Heterogeneous Data. *IEEE Access*.
- Liu, W., Suzuki, Y., & Du, S. (2024). Forecasting the Stock Price of Listed Innovative SMEs Using Machine Learning Methods Based on Bayesian optimization: Evidence from China. *Computational Economics*, 63(5), 2035–2068.
- Margono, S. (2005). *Metodologi penelitian pendidikan*.
- Moseane, O., Tsoku, J. T., & Metsileng, D. (2024). Hybrid time series and ANN-based ELM model on JSE/FTSE closing stock prices. *Frontiers in Applied Mathematics and Statistics*, 10, 1454595.
- Muklis, F. (2016). Perkembangan dan tantangan pasar modal Indonesia. *Al-Masraf: Jurnal Lembaga Keuangan Dan Perbankan*, 1(1), 65–76.
- Patel, J., Shah, S., Thakkar, P., & Kotecha, K. (2015). Predicting stock and stock price index movement using trend deterministic data preparation and machine learning techniques. *Expert Systems with Applications*, 42(1), 259–268.
- Pengumuman Pembagian Dividen Tunai Tahun Buku 2024. (2025). In *Adaro Minerals Indonesia Tbk*. <https://www.adarominerals.id/investor/>
- Prianti, D., Anggi, M. M., Sahfitri, N. D., Sari, R. T. V., & Harahap, M. I. (2023). Analisis Perbandingan Saham ADRO Dan ADMR Pasca Covid 19. *Ekonomi Bisnis Manajemen Dan Akuntansi (EBMA)*, 4(1), 1754–1758.
- Qiu, M., Song, Y., & Akagi, F. (2016). Application of artificial neural network for the prediction of stock market returns: The case of the Japanese stock market. *Chaos, Solitons & Fractals*, 85, 1–7.
- Rather, A. M., Agarwal, A., & Sastry, V. N. (2015). Recurrent neural network and a hybrid model for prediction of stock returns. *Expert Systems with Applications*, 42(6), 3234–3241.
- Rustiyana, R., Prasetyo, D., Saragih, Y. M., Prayudani, S., Permana, A. A. J., & Judijanto, L. (2025). *Pengantar Ilmu Komputer*. PT. Sonpedia Publishing Indonesia.
- Safitri, L. I. (2016). *Pemodelan Vector Autoregressive With Exogenous Input (Varx) Dan Artificial Neural Networ Untuk Peramalan Data Penumpang Kereta Api*. Institut Technology Sepuluh

Nopember.

- Sahi, M. (2023). *Prediksi Harga Cryptocurrency berdasarkan model Artificial Neural Network*. Universitas Islam Negeri Maulana Malik Ibrahim.
- Sahi, M., Faisal, M., Arif, Y. M., & Crysdian, C. (2023). Analysis of the Use of Artificial Neural Network Models in Predicting Bitcoin Prices. *Applied Information System and Management*, 6(2), 91–96.
- Sahi, M., & Galib, G. R. H. (2025). Artificial Intelligence Application of Back-propagation Neural Network in Cryptocurrency Price Prediction. *IJEIE: International Journal of Electrical and Intelligent Engineering*, 1(1), 32–46.
- Saputra, S., Marswandi, E. D. P., & Hendri, W. (2024). Risiko Geopolitik dan Indeks Harga Saham Gabungan Indonesia. *Jurnal Ekonomi Manajemen Perbankan*, 6(2), 98–108.
- Saravanos, C., & Kanavos, A. (2025). Forecasting stock market volatility using social media sentiment analysis. *Neural Computing and Applications*, 37(17), 10771–10794.
- Sarie, F., Sutaguna, I. N. T., Par, S. S. T., Par, M., Suiroaka, I. P., St, S., Darwin Damanik, S. E., Se, M., Efrina, G., & Sari, R. (2023). *Metodelogi penelitian*. Cendikia Mulia Mandiri.
- Sartika, E. (2010). Pengolahan data berskala ordinal (Ordinal data scale analysis). *Sigma-Mu*, 2(1), 68–69. Politeknik Negeri Bandung.
- Selvin, S., Vinayakumar, R., Gopalakrishnan, E. A., Menon, V. K., & Soman, K. P. (2017). Stock price prediction using LSTM, RNN and CNN-sliding window model. *2017 International Conference on Advances in Computing, Communications and Informatics (Icacci)*, 1643–1647.
- Septirani, N., & Febriyanti, F. (2022). PRESPEKTIF HUKUM EKONOMI SYARIAH DALAM JUAL BELI SAHAM: PRESPEKTIF HUKUM EKONOMI SYARIAH DALAM JUAL BELI SAHAM. *Journal of Business Education and Social*, 3(2).
- Shleifer, A. (2000). *Inefficient markets: An introduction to behavioural finance*. Oup Oxford.
- Sihombing, Y. O., & Situmorang, N. V. (2024). Prediksi Sentimen Pada Teks Media Sosial Corporate University Menggunakan RoBERTa. *Prosiding PITNAS Widyaiswara*, 1, 302–316.
- Sileyew, K. J. (2019). Research design and methodology. *Cyberspace*, 1–12.
- Sivanandam, S., & Paulraj, M. (2009). *Introduction to artificial neural networks*. Vikas Publishing House.
- Skill And Performance Estimates, D. L. P. (2025). Agniva Maiti, Ue Kiao.(2025). Training Process Of Deep Learning Models, OpenGenius IQ: Lear Algorithms, DL, System Design. Alec Radford, Karthik Narasimhan, Tim Salimans, Ilya Sutskever, et al.(2018). Improving language Understanding By Generative Pre-Tra. *Deep Learning: Teori, Algoritma, Dan Aplikasi*, 231.

- Sukendro, G. G., Yoedjadi, M. G., & Pandrianto, N. (2024). *Kecerdasan Buatan dan Evolusi Media dan Komunikasi*. Gramedia Pustaka Utama.
- Thian, A. (2024). *Ekonomi & Keuangan Syariah*. Penerbit Andi.
- Thomas, A. J., Petridis, M., Walters, S. D., Gheytaasi, S. M., & Morgan, R. E. (2017). Two hidden layers are usually better than one. *Engineering Applications of Neural Networks: 18th International Conference, EANN 2017, Athens, Greece, August 25–27, 2017, Proceedings*, 279–290.
- Tribuana, D., Maramis, L., Resky, A. M., & Hidayat, R. (2025). *Deep Learning*. Serasi Media Teknologi.
- Ulama, B. S. S., & Utami, A. T. W. (2016). Penerapan Backpropagation untuk Meningkatkan Efektivitas Waktu dan Akurasi pada Data Wall-Following Robot Navigation. *Jurnal Sains Dan Seni ITS*, 4(2), 15720.
- Urva, G., Albanna, I., Sungkar, M. S., Gunawan, I. M. A. O., Adhicandra, I., Ramadhan, S., Rahardian, R. L., Handayanto, R. T., Ariana, A. A. G. B., & Atika, P. D. (2023). *PENERAPAN DATA MINING DI BERBAGAI BIDANG: Konsep, Metode, dan Studi Kasus*. PT. Sonpedia Publishing Indonesia.
- Wibowo, A. (2025). Pengantar AI, Big Data dan Ilmu Data. *Penerbit Yayasan Prima Agus Teknik*.
- Zhang, G., Patuwo, B. E., & Hu, M. Y. (1998). Forecasting with artificial neural networks:: The state of the art. *International Journal of Forecasting*, 14(1), 35–62.
- Zhang, Y., Li, J., Wang, H., & Choi, S.-C. T. (2021). Sentiment-guided adversarial learning for stock price prediction. *Frontiers in Applied Mathematics and Statistics*, 7, 601105.