

Perkiraan Harga Cabai 2023-2024 dengan Penerapan Metode Backpropagation di Kota Singkawang

Dimas Trianda¹, Solikhun², Abdi Rahim Damanik³

^{1,2}Program Studi Teknik Informatika, STIKOM Tunas Bangsa, Indonesia

³Program Studi Sistem Informasi, STIKOM Tunas Bangsa, Indonesia

Article Info

Article history:

Received Dec 14, 2023

Revised Jan 30, 2024

Accepted Feb 09, 2024

Kata Kunci:

Prediksi harga
Propagasi balik
Gradien konjungsi
Jaringan syaraf tiruan
Prediksi cabai

Keywords:

Price prediction
Backpropagation
Conjugate gradient
Artificial neural networks
Chili prediction

ABSTRAK

Penelitian ini bertujuan untuk mengembangkan model prediksi harga cabai yang dapat memberikan kontribusi signifikan bagi pemangku kepentingan pasar di Kota Singkawang. Dengan menggunakan metode jaringan saraf tiruan, model arsitektur 3-7-1 dikembangkan dan diuji menggunakan data harga cabai dari tahun 2019 hingga 2022 yang telah dinormalisasi. Data historis yang diperoleh dari Badan Pusat Statistik Kota Singkawang menjadi dasar utama dalam pengembangan model ini. Hasil penelitian menunjukkan bahwa model arsitektur 3-7-1 mampu memberikan prediksi harga cabai dengan tingkat akurasi yang kompetitif meskipun sedikit lebih rendah dibandingkan dengan beberapa model lain yang diuji. Namun, keunggulan model ini terletak pada nilai Mean Squared Error (MSE) yang lebih rendah, menandakan prediksi yang lebih mendekati harga sebenarnya. Dalam konteks pasar cabai di Kota Singkawang, keakuratan prediksi harga cabai sangat penting bagi para pelaku pasar untuk mengantisipasi fluktuasi harga. Oleh karena itu, diharapkan model ini dapat memberikan pandangan yang lebih tepat dan berguna bagi para pemangku kepentingan dalam mengambil keputusan terkait stok, harga, dan strategi pasar. Dengan adanya model ini, diharapkan dapat meminimalkan risiko serta meningkatkan efisiensi dalam aktivitas perdagangan cabai di Kota Singkawang.

ABSTRACT

This research aims to develop a chili price prediction model that can provide a significant contribution to market stakeholders in Singkawang City. Using artificial neural network methods, the 3-7-1 architectural model was developed and tested using normalized chili price data from 2019 to 2022. Historical data obtained from the Singkawang City Central Statistics Agency is the main basis for this development model. The research results show that the 3-7-1 architectural model can provide chili price predictions with a competitive level of accuracy, although slightly lower than several other models tested. However, the advantage of this model lies in its lower Mean Squared Error (MSE) value, indicating predictions that are closer to the actual price. In the context of the chili market in Singkawang City, the accuracy of chili price predictions is very important for market players to prevent price contagion. Therefore, it is hoped that this model can provide a more precise and useful view for stakeholders in making decisions regarding stock, prices, and market strategy. With this model, it is hoped that it can minimize risks and increase efficiency in chili trading activities in Singkawang City.

This is an open access article under the [CC BY-NC](https://creativecommons.org/licenses/by-nc/4.0/) license.



Corresponding Author:

Dimas Trianda,
Teknik Informatika, STIKOM Tunas Bangsa,
Jln. Sudirman No. 1, Pematang Siantar, Sumatera Utara, Indonesia.
Email: trianda28721@gmail.com

1. PENDAHULUAN

Cabai telah menjadi bagian *integral* dari budaya kuliner Indonesia, tidak hanya sebagai bumbu pelengkap tetapi juga sebagai *komoditas* penting dalam industri pertanian (Puspita et al., 2023), (Waluyo, 2020), (R. M. Putri et al., 2022). Namun, *fluktuasi* harga cabai yang sulit diprediksi telah menjadi tantangan serius bagi stabilitas pasar dan kehidupan sehari-hari masyarakat (Paksi et al., 2023), (Rohman & Andadari, 2021). Dinamika harga yang tidak stabil ini tidak hanya memengaruhi para petani cabai, tetapi juga mengakibatkan dampak yang *signifikan* pada konsumen akhir dan ekonomi secara keseluruhan (Pradana, 2021), (Fauzi et al., 2023). Kota Singkawang, yang dikenal sebagai salah satu pusat distribusi cabai utama di Indonesia, sering menghadapi variasi harga yang *signifikan* (Firdaus, 2021). Berbagai faktor, mulai dari kondisi cuaca yang tak terduga, *fluktuasi* musim tanam, hingga perubahan dalam permintaan pasar lokal dan global, semuanya berkontribusi pada ketidakpastian harga cabai yang seringkali sulit diprediksi. Dampaknya terasa luas, memengaruhi keputusan konsumen, kesejahteraan petani, serta stabilitas ekonomi wilayah tersebut. Pada upaya untuk mengatasi ketidakpastian ini, perlu adanya penelitian yang lebih mendalam terkait perkiraan harga cabai. Salah satu pendekatan yang menarik untuk *dieksplorasi* adalah penggunaan metode *Backpropagation* dalam jaringan saraf tiruan (*Artificial Neural Network/ANN*).

Metode ini telah terbukti efektif dalam memprediksi harga *komoditas* pertanian lainnya, seperti beras, gandum, dan kopi (Sen et al., 2020), (S. H. Putri et al., 2021). Namun, pengaplikasiannya dalam konteks prediksi harga cabai di Kota Singkawang masih merupakan ranah yang perlu lebih dijelajahi. Penelitian ini bertujuan untuk *meksplorasi* potensi metode *Backpropagation* dalam memprediksi harga cabai di pasar Singkawang. Diharapkan bahwa penggunaan teknologi ini tidak hanya akan memberikan prediksi yang lebih akurat dan dapat diandalkan terkait harga cabai, tetapi juga akan memberikan wawasan yang lebih dalam terhadap faktor-faktor yang memengaruhi pasar lokal (Aulia et al., 2021), (Irianti et al., 2022), (Suradiradja, 2021). Hal ini akan memberikan manfaat yang *signifikan* bagi para petani, pedagang, konsumen, dan pemangku kepentingan lainnya dalam industri cabai di Singkawang (Padapi et al., 2021), (Rozaini & Silaban, 2023). Melalui penggabungan antara kecerdasan buatan dengan *analisis* yang mendalam terhadap *variabel-variabel* yang mempengaruhi harga cabai, diharapkan akan tercipta sebuah kerangka kerja yang dapat membantu mengurangi ketidakpastian harga dan memberikan pandangan yang lebih terarah bagi keputusan bisnis maupun konsumen.

2. METODE PENELITIAN

Bagian Metode Penelitian ini menjabarkan secara terperinci pendekatan yang digunakan dalam penelitian ini untuk memprediksi harga cabai di Kota Singkawang dengan menggunakan metode *Conjugate Gradient Polak-Rebiere*. Langkah-langkah *metodologis* yang diuraikan dalam bagian ini bertujuan untuk memberikan gambaran menyeluruh tentang proses pengumpulan data, pengolahan informasi, serta langkah-langkah teknis dalam pembentukan dan *evaluasi* model prediksi. Melalui pendekatan yang terperinci ini, diharapkan akan terungkap bagaimana metode *Conjugate Gradient Polak-Rebiere* diaplikasikan secara efektif dalam konteks prediksi harga cabai, memberikan pemahaman yang jelas tentang proses penelitian dan *metodologi* yang diterapkan, kerangka kerja yang disiapkan digambarkan pada gambar 1 berikut :



Gambar 1. Kerangka Kerja Penelitian

Berdasarkan kerangka kerja penelitian pada gambar 1, dapat diuraikan tahapan-tahapan penelitian sebagai berikut :

1. **Mengidentifikasi Masalah**
Identifikasi fluktuasi harga cabai di Kota Singkawang sebagai masalah utama yang mempengaruhi pasar dan kehidupan sehari-hari masyarakat.
2. **Menganalisis Masalah**
Menganalisis faktor-faktor *internal* dan karakteristik pasar yang berkontribusi terhadap *fluktuasi* harga cabai di Kota Singkawang.
3. **Menentukan Tujuan**
Menetapkan tujuan penelitian untuk mengembangkan model prediksi harga cabai yang akurat menggunakan metode *Conjugate Gradient Polak-Rebiere* dalam Jaringan Saraf Tiruan.
4. **Mencari dan Mempelajari Literatur**
Melakukan pencarian *literatur* terkait prediksi harga cabai dengan menggunakan metode Jaringan Saraf Tiruan, serta mempelajari penelitian terdahulu yang *relevan*.
5. **Pengumpulan Data**
Mengumpulkan data historis harga cabai dari website BPS Kota Singkawang (<https://singkawangkota.bps.go.id/indikator/102/556/1/harga-cabai-rawit-1-kg-.html>) sebagai sumber data utama untuk melatih dan menguji model prediksi.
6. **Menganalisis Data dengan Metode JST**
Menggunakan metode Jaringan Saraf Tiruan (JST) untuk menganalisis data historis harga cabai. Proses ini melibatkan pengolahan data, pembentukan *input* dan *output* untuk model JST.
7. **Mengimplementasikan Algoritma JST**
Implementasi algoritma *Conjugate Gradient Polak-Rebiere* dalam JST sebagai metode utama untuk membangun model prediksi harga cabai.
8. **Melatih dan Menguji Hasil Penelitian**
Melakukan proses pelatihan (*training*) dan pengujian (*testing*) model JST menggunakan data historis yang telah dikumpulkan. *Evaluasi* dilakukan terhadap akurasi dan kinerja model dalam memprediksi harga cabai.
9. **Menarik Kesimpulan**
Menarik kesimpulan merupakan langkah akhir dalam rangka kerja penelitian ini. Proses penarikan kesimpulan didasarkan pada telaah *literatur* yang telah dilakukan, *analisis* permasalahan, serta hasil-hasil yang dihasilkan dari penelitian ini. Kesimpulan yang diperoleh meliputi nilai prediksi harga *komoditas* cabai di wilayah Kota Singkawang. Dari hasil prediksi ini, dapat dinilai tingkat akurasi prediksi yang diperoleh menggunakan metode Jaringan Saraf Tiruan dengan algoritma *Conjugate Gradient Polak-Rebiere*.

3. HASIL DAN PEMBAHASAN

Bagian ini akan menampilkan hasil *analisis* terhadap data historis harga cabai, menjadi landasan prediksi harga cabai pada tahun 2023 -2024. Data yang digunakan dalam penelitian mencakup rentang waktu 2019 hingga 2022, diperoleh dari Badan Pusat Statistik (BPS) Kota Singkawang. Tujuan *analisis* ini adalah mengidentifikasi pola dan tren *fluktuasi* harga cabai selama periode penelitian, membentuk dasar ramalan harga cabai untuk tahun 2023 - 2024. Pembahasan akan menyoroti prediksi harga cabai berdasarkan *analisis* data historis, mempertimbangkan faktor-faktor yang memengaruhi pasar cabai di Kota Singkawang, serta memperkuat landasan hasil prediksi. Berikut ini adalah data harga *komoditas* cabai di Kota Singkawang pada tahun 2019 - 2022 :

Tabel 1. Data Harga Cabai Tahun 2019 - 2022

No	Bulan Rata - rata	2019	2020	2021	2022
1	Januari	65458	51742	83988	68619
2	Februari	61792	64040	92738	63321
3	Maret	56600	60750	91071	62000
4	April	51042	56857	86048	60583
5	Mei	55867	51934	64012	62607
6	Juni	59500	48283	49798	60495
7	Juli	65375	49771	51857	63060
8	Agustus	77367	68929	59464	61774
9	September	84583	64000	59038	61524
10	Oktober	82625	67143	52762	60464
11	November	67267	64036	50774	57429
12	Desember	35125	77857	69743	57238

Implementasi sistem prediksi menggunakan metode *Conjugate Gradient Polak-Ribiere* untuk harga cabai di Kota Singkawang, *dataset* yang digunakan terdiri dari data tahun 2019, 2020, dan 2021 sebagai data *training* dengan target pada tahun 2021. Sedangkan, untuk data *testing*, digunakan data dari tahun 2020, 2021, dan 2022 dengan target pada tahun 2022. Hal ini memungkinkan penggunaan data historis sebagai landasan untuk melatih dan menguji model prediksi guna mengestimasi harga cabai pada tahun-tahun yang berbeda. Dengan demikian, penggunaan rentang waktu yang berbeda sebagai data *training* dan *testing* memungkinkan *evaluasi* kinerja model dalam memprediksi harga cabai di masa yang akan datang dengan pendekatan yang lebih akurat dan terperinci.

a) Pembagian Data

Tahap awal yang diperlukan adalah memisahkan data menjadi dua bagian, yaitu data *training* dan data *Testing*. Dalam contoh ini, penulis menggunakan *dataset* dari tahun 2019, 2020, dan 2021 sebagai data *training* yang memiliki target pada tahun 2021. Sementara itu, untuk data *Testing*, pengarang memilih data dari tahun 2020, 2021, dan 2022 dengan target pada tahun 2022.

Tabel 2. Data *Training*

No	Bulan Rata - rata	Harga 2019	Harga 2020	Harga 2021	Target 2021
1	Januari	65458	51742	83988	83988
2	Februari	61792	64040	92738	92738
3	Maret	56600	60750	91071	91071
4	April	51042	56857	86048	86048
5	Mei	55867	51934	64012	64012
6	Juni	59500	48283	49798	49798
7	Juli	65375	49771	51857	51857
8	Agustus	77367	68929	59464	59464
9	September	84583	64000	59038	59038
10	Oktober	82625	67143	52762	52762
11	November	67267	64036	50774	50774
12	Desember	35125	77857	69743	69743

Tabel 3. Data *Testing*

No	Bulan Rata - rata	Harga 2020	Harga 2021	Harga 2022	Target 2022
1	Januari	51742	83988	68619	68619
2	Februari	64040	92738	63321	63321
3	Maret	60750	91071	62000	62000
4	April	56857	86048	60583	60583
5	Mei	51934	64012	62607	62607
6	Juni	48283	49798	60495	60495
7	Juli	49771	51857	63060	63060
8	Agustus	68929	59464	61774	61774
9	September	64000	59038	61524	61524
10	Oktober	67143	52762	60464	60464
11	November	64036	50774	57429	57429
12	Desember	77857	69743	57238	57238

Catatan :

- 1) Memisahkan *dataset* menjadi dua bagian untuk keperluan data *training* dan *testing* tidak harus merujuk pada pembagian yang seimbang, terutama jika *dataset* yang digunakan terbatas. Yang terpenting adalah memastikan perbedaan antara data *training* dan target *training* dengan data *testing* dan target *testing*.
- 2) Tahun-tahun dalam *dataset* harga cabai dapat digunakan ulang sebagai data *testing* atau target, tetapi penting untuk memastikan bahwa urutan dan penempatannya berbeda antara data *training* dan data *testing*.
- 3) Jumlah *input* pada tahun-tahun data *training* harus serupa dengan data *testing*. Seperti terlihat pada tabel 2, terdapat 3 *input* dengan 1 target. Begitu juga dengan tabel 3, yang memiliki 3 *input* dan 1 target pula.

b) Normalisasi

Penting untuk melaksanakan *normalisasi* pada data *training* dan data *testing* guna mengubah nilai data ke dalam rentang 0 hingga 1, yaitu antara 0,1 hingga 0,9. Proses *normalisasi* ini akan *diintegrasikan* dan dimasukkan ke dalam *platform* aplikasi *Matlab*. Berikut adalah rumus *normalisasi* yang diaplikasikan.

$$x' = \frac{0.8 (x - a)}{b - a} + 0.1$$

Keterangan :

x' = Hasil *Normalisasi*

0.8 = Nilai default *normalisasi* nilai optimum

X = Data yang akan *dinormalisasi*

b = Nilai data tertinggi

a = Nilai data terendah

0.1 = Nilai default *normalisasi* nilai minimum

Sebelum dilakukan *normalisasi*, kita harus mengetahui nilai data tertinggi (b) dan data terendah (a) dari tabel data *training* maupun data *testing*.

$$x' = \frac{0.8 (65458 - 35125)}{92738 - 35125} + 0.1 = 0,521196605$$

Tabel 4. Data *Training* Setelah *Normalisasi*

No	Bulan Rata - rata	Harga 2019	Harga 2020	Harga 2021	Target 2021
1	Januari	0.521196605	0.33073959	0.778499644	0.778499644
2	Februari	0.470291427	0.501506604	0.9	0.9
3	Maret	0.398196588	0.455822471	0.876852446	0.876852446
4	April	0.321019562	0.401765227	0.807104299	0.807104299
5	Mei	0.388018329	0.333405655	0.501117803	0.501117803

No	Bulan Rata - rata	Harga 2019	Harga 2020	Harga 2021	Target 2021
6	Juni	0.438465277	0.282708764	0.303745682	0.303745682
7	Juli	0.520044087	0.303370767	0.332336452	0.332336452
8	Agustus	0.686562061	0.56939406	0.43796539	0.43796539
9	September	0.786761668	0.500951174	0.432050058	0.432050058
10	Oktober	0.75957336	0.544594102	0.34490306	0.34490306
11	November	0.546315936	0.501451061	0.317298179	0.317298179
12	Desember	0.1	0.693366081	0.580697065	0.580697065

Tabel 5. Data *Testing* Setelah *Normalisasi*

No	Bulan Rata - rata	Harga 2020	Harga 2021	Harga 2022	Target 2022
1	Januari	0.162247216	0.742537397	0.465961084	0.465961084
2	Februari	0.383558655	0.9	0.370619728	0.370619728
3	Maret	0.324352716	0.870001125	0.346847374	0.346847374
4	April	0.254295355	0.779608593	0.32134743	0.32134743
5	Mei	0.165702396	0.383054774	0.357770779	0.357770779
6	Juni	0.1	0.127263525	0.319763806	0.319763806
7	Juli	0.12677764	0.164316725	0.365922843	0.365922843
8	Agustus	0.471539759	0.301210213	0.34278034	0.34278034
9	September	0.382838826	0.293544033	0.338281408	0.338281408
10	Oktober	0.439399393	0.180602857	0.319205939	0.319205939
11	November	0.383486672	0.144827354	0.26458891	0.26458891
12	Desember	0.632205601	0.48618828	0.261151726	0.261151726

c) Menentukan Model Arsitektur

Langkah berikutnya melibatkan penentuan struktur model jaringan yang akan digunakan untuk melakukan *analisis* dan mendukung perhitungan dalam proses prediksi. Tidak ada peraturan yang mengikat dalam pemilihan model *arsitektur* jaringan tertentu. Umumnya, model *arsitektur* dimulai dari skala yang kecil dan bertahap meningkat ke skala yang lebih besar. Pada situasi ini, terdapat lima model *arsitektur* yang digunakan, yaitu:

- 1) 3-5-1 (3 sebagai *input*, 1 lapisan tersembunyi dengan 5 *neuron*, dan 1 *output*)
- 2) 3-10-1 (3 sebagai *input*, 1 lapisan tersembunyi dengan 10 *neuron*, dan 1 *output*)
- 3) 3-5-10-1 (3 sebagai *input*, 2 lapisan tersembunyi dengan 5 *neuron* dan 10 *neuron*, dan 1 *output*)
- 4) 3-7-1 (3 sebagai *input*, 1 lapisan tersembunyi dengan 7 *neuron*, dan 1 *output*)
- 5) 3-9-1 (3 sebagai *input*, 1 lapisan tersembunyi dengan 9 *neuron*, dan 1 *output*).

Catatan: *Input* dengan nilai 3 telah ditentukan berdasarkan data *input* pada tabel dan tidak dapat diubah karena sudah ditetapkan pada awal. Lapisan tersembunyi dapat diubah sesuai kebutuhan, dapat menggunakan 1 atau 2 lapisan tersembunyi. Jumlah *neuron* dalam lapisan tersembunyi juga dapat disesuaikan sesuai preferensi untuk mencari hasil terbaik, seperti dalam kasus ini menggunakan 5, 10, 7, dan 9 *neuron*. Sementara *output* yang bernilai 1 ditentukan berdasarkan target pada tabel masing-masing data yang hanya memuat satu nilai.

d) Pelatihan (*Training*) dan Pengujian (*Testing*) Data

Langkah selanjutnya dalam proses adalah menjalankan proses pelatihan data. Tujuan utama dari pelatihan data adalah untuk mengajarkan sistem agar dapat beroperasi secara konsisten dan akurat, berdasarkan pada pola yang *teridentifikasi* dalam model jaringan yang telah ditetapkan sebelumnya. Penggunaan *dataset training* untuk mengoptimalkan bobot dan *parameter* jaringan merupakan bagian *integral* dari pelatihan. Di sisi lain, pengujian data dilakukan untuk mengevaluasi kemampuan jaringan dalam mengenali pola-pola baru yang tidak ditemui selama proses pelatihan. Pengujian ini merupakan langkah penting untuk memastikan bahwa model jaringan dapat melakukan *generalisasi* dengan baik terhadap data baru dan tidak terlihatnya *overfitting*.

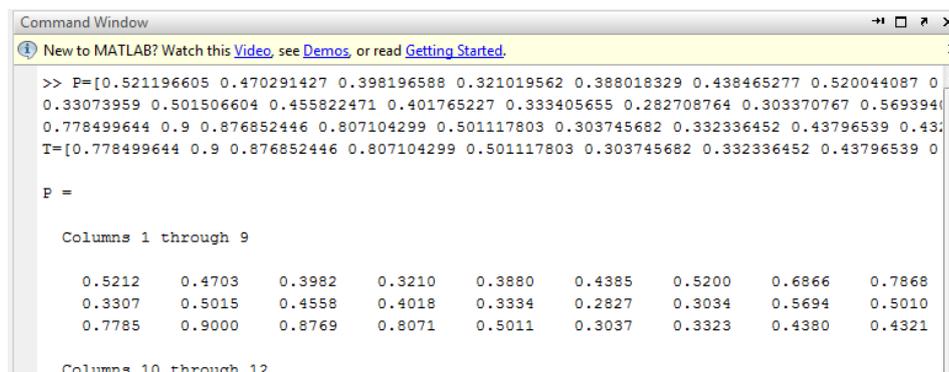
Setelah melakukan pengujian data dengan 5 *arsitektur* yang diuji, didapatkan *MSE* yang paling rendah adalah *arsitektur* 3-7-1, maka penulis menggunakan *arsitektur* ini untuk melakukan prediksi harga cabai di kota Singkawang. Model 3-7-1 yang berhasil mencapai tingkat akurasi sebesar 75%, Meskipun tingkat akurasi ini lebih rendah daripada model 3-5-10-1 yang berhasil mencapai tingkat akurasi sebesar 83%, namun model *arsitektur* 3-7-1 memiliki nilai *Mean Square Error (MSE)* yang lebih kecil jika dibandingkan

dengan keempat model *arsitektur* lainnya. Penting untuk dicatat bahwa semakin kecil nilai *MSE*, semakin baik pula hasil prediksi yang akan dilakukan nantinya.

Tabel 6. Data Perbandingan *Arsitektur* Terbaik

Conjugate Gradient Polak-Ribiere (traincgp)				
Arsitektur	Epoch	Waktu	MSE	Accuracy
3-5-1	263	0:02:08	0.025748026	67%
3-10-1	99	0:00:05	0.027175223	58%
3-5-10-1	92	0:00:06	0.081993569	83%
3-7-1	2000	0:02:14	0.010039332	75%
3-9-1	2000	0:02:08	0.09096289	75%

Selanjutnya melakukan Pelatihan dan Pengujian dengan Model *Arsitektur* 3-7-1 yang dapat dilihat pada gambar berikut :



```

Command Window
New to MATLAB? Watch this Video, see Demos, or read Getting Started.
>> P=[0.521196605 0.470291427 0.398196588 0.321019562 0.388018329 0.438465277 0.520044087 0
0.33073959 0.501506604 0.455822471 0.401765227 0.333405655 0.282708764 0.303370767 0.569394
0.778499644 0.9 0.876852446 0.807104299 0.501117803 0.303745682 0.332336452 0.43796539 0.43
T=[0.778499644 0.9 0.876852446 0.807104299 0.501117803 0.303745682 0.332336452 0.43796539 0
P =
Columns 1 through 9
0.5212 0.4703 0.3982 0.3210 0.3880 0.4385 0.5200 0.6866 0.7868
0.3307 0.5015 0.4558 0.4018 0.3334 0.2827 0.3034 0.5694 0.5010
0.7785 0.9000 0.8769 0.8071 0.5011 0.3037 0.3323 0.4380 0.4321
Columns 10 through 12

```

Gambar 2. *Input Data Training* di Matlab

Keterangan:

P = *Input data training*

T = *Target data training*

Kemudian ketikkan kode program berikut :

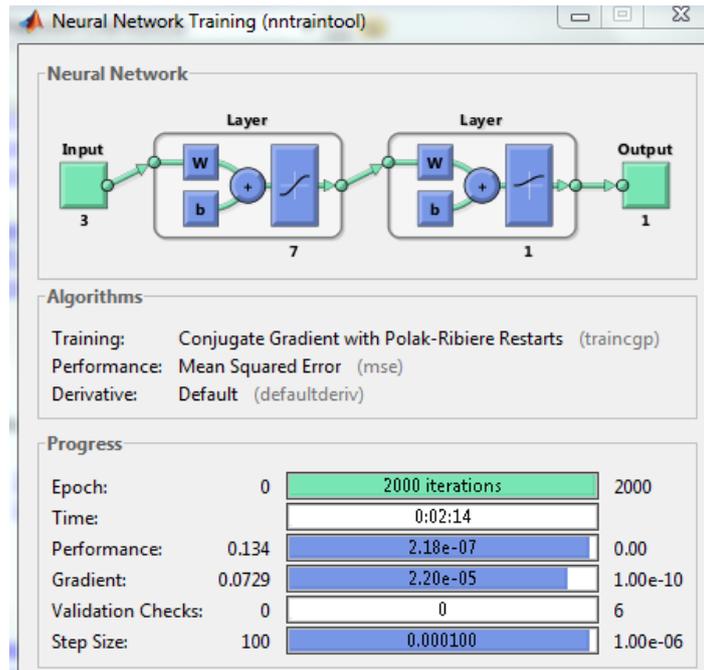
```

net=newff(minmax(P),[7,1],{'tansig','logsig'},'traincgp');
net.LW{1,1};
net.b{1};
net.LW{2,1};
net.b{2};
net.trainParam.epochs=2000;
net.trainParam.show = 25;
net.trainParam.showCommandLine = false;
net.trainParam.showWindow = true;
net.trainParam.goal = 0;
net.trainParam.time = inf;
net.trainParam.min_grad= 1e-10;
net.trainParam.max_fail = 6;
net.trainParam.searchFcn = 'srchcha';
net=train(net,P,T)

```

Gambar 3. *Parameter Default Conjugate Gradient Polak-Ribiere*

Gambar hasil pelatihan dengan algoritma *Conjugate gradient Polak-Ribiere* disajikan pada Gambar 4 seperti berikut:



Gambar 4. Hasil Pelatihan dengan Model Arsitektur 3-7-1

Selanjutnya ketikkan kode berikut:

```
[a,Pf,Af,e,Perf]=sim(net,P,[],[],T)
```

Gambar 5. Parameter untuk mendapatkan nilai a (Output) dan nilai e (error) data training.

Tabel 7. Hasil Data Training dengan Model 3-7-1

Data	Target	Output	Error	SSE
1	0.7785	0.778548841	-4.92E-05	2.42E-09
2	0.9	0.899110102	0.000889898	7.92E-07
3	0.8769	0.878017123	-0.001164677	1.36E-06
4	0.8071	0.806645573	0.000458726	2.10E-07
5	0.5011	0.501173887	-5.61E-05	3.15E-09
6	0.3037	0.303309312	0.00043637	1.90E-07
7	0.3323	0.332536471	-0.000200019	4.00E-08
8	0.438	0.437868534	9.69E-05	9.38E-09
9	0.4321	0.432041735	8.32E-06	6.93E-11
10	0.3449	0.344887384	1.57E-05	2.46E-10
11	0.3173	0.317421099	-0.00012292	1.51E-08
12	0.5807	0.580692255	4.81E-06	2.31E-11

Jlh SSE : 2,62E-06

MSE : 2,18E-07

Selanjutnya input normalisasi data testing ke matlab.

Kemudian ketikkan kode program berikut:

```
[a,Pf,Af,e,Perf]=sim(net,PP,[],[],TT)
```

Gambar 6. Parameter untuk mendapatkan nilai a (Output) dan nilai e (error) data testing.

Tabel 8. Hasil Akurasi Data Testing dengan Model 3-7-1

Data	Target	Output	Error	SSE	Akurasi
1	0.466	0.603224737	-0.137263653	0.01884131	1
2	0.3706	0.49830442	-0.127684692	0.01630338	1
3	0.3468	0.501085891	-0.154238517	0.02378952	1

Data	Target	Output	Error	SSE	Akurasi
4	0.3213	0.486905388	-0.165557958	0.027409437	1
5	0.3578	0.300697967	0.057072812	0.003257306	0
6	0.3198	0.346580244	-0.026816438	0.000719121	1
7	0.3659	0.377976409	-0.012053566	0.000145288	1
8	0.3428	0.334506566	0.008273774	6.84553E-05	0
9	0.3383	0.323749882	0.014531526	0.000211165	0
10	0.3192	0.445050994	-0.125845055	0.015836978	1
11	0.2646	0.379671362	-0.115082452	0.013243971	1
12	0.2612	0.286569304	-0.025417578	0.000646053	1

Jlh SSE : 0,120471987

MSE : 0,010039332

Akurasi :75%

Keterangan :

Data = 12 Bulan

Target = Diambil dari *normalisasi* target data *testing*

Output = Diambil dari nilai a data *testing* hasil *Matlab*

Error = Diperoleh dari target – output atau dari nilai data *testing* hasil dari *Matlab*

SSE = $Error^2$

Jlh SSE = Total nilai SSE

MSE = Jlh SSE / 12 (banyaknya data)

Akurasi = Bernilai 1 (benar) apabila nilai $error \leq 0,003$ (If $Error \leq 0,003;1;0$)

0,003 = Minimum *error* yang digunakan (0,003-0,001)

75% = Diperoleh dari Jumlah benar / Jumlah data * 100 ($9/12*100 = 75\%$)

e) Melakukan Prediksi Data

Model *arsitektur* 3-7-1 akan digunakan untuk melakukan prediksi data harga cabai di Kota Singkawang karena dinilai sebagai model *arsitektur* yang paling optimal. Untuk mendapatkan nilai a (*output*) yang nantinya akan dimasukkan kedalam tabel perhitungan, masukkan *normalisasi* data untuk prediksi berdasarkan tabel 5 ke *Matlab*, setelah itu masukkan kode berikut :

```
net=newff(minmax(P),[7,1],{'tansig','logsig'},'traincgp');
net.LW{1,1};
net.b{1};
net.LW{2,1};
net.b{2};
net.trainParam.epochs=2000;
net.trainParam.show = 25;
net.trainParam.showCommandLine = false;
net.trainParam.showWindow = true;
net.trainParam.goal = 0;
net.trainParam.time = inf;
net.trainParam.min_grad= 1e-10;
net.trainParam.max_fail = 6;
net.trainParam.searchFcn = 'srchcha';
net=train(net,P,T)
[a,Pf,Af,e,Perf]=sim(net,P,[],[],T)
```

Gambar 7. Parameter Default Conjugate Gradient Polak-Ribiere

Tabel 9. Prediksi Harga Cabai di Kota Singkawang Tahun 2023

Data	Bulan Rata - rata	Data Real	Target	Target Prediksi	Prediksi
1	Januari	68619	0.465961084	0.466071858	62445.82977
2	Februari	63321	0.370619728	0.369326489	61069.50596
3	Maret	62000	0.346847374	0.348288528	60770.21468
4	April	60583	0.32134743	0.321001544	60382.02322
5	Mei	62607	0.357770779	0.358023527	60908.7072
6	Juni	60495	0.319763806	0.319846548	60365.59196

Data	Bulan Rata - rata	Data Real	Target	Target Prediksi	Prediksi
7	Juli	63060	0.365922843	0.36533598	61012.73598
8	Agustus	61774	0.34278034	0.342305666	60685.10097
9	September	61524	0.338281408	0.338971797	60637.67253
10	Oktober	60464	0.319205939	0.319442373	60359.84206
11	November	57429	0.26458891	0.264576192	59579.30205
12	Desember	57238	0.261151726	0.260995669	59528.36463

Nilai Max = **68619**
Nilai Min = **57238**
Nilai Max - Nilai Min = **11381**

Keterangan :

Data Real = Diperoleh dari data terakhir Harga Cabai tahun 2022 (berdasarkan Tabel 1)
 Target = *Normalisasi* Data Real
 Nilai Max = Nilai terbesar dari data real
 Nilai Min = Nilai terendah dari data real
 Target Prediksi = Nilai a (*output*) yang di peroleh dari *Matlab*
 Prediksi = $((\text{Target Prediksi}-0,1)*(\text{Hasil max-min}))/0,8+\text{min}$

Pada Tabel berikut akan disajikan data awal sebelum di lakukan prediksi dengan data hasil prediksi yang dapat dilihat pada Tabel 10 :

Tabel 10. Perbandingan Data Awal dengan Hasil Prediksi

Data	Bulan Rata - rata	Harga 2019	Harga 2020	Harga 2021	Harga 2022	Prediksi 2023
1	Januari	65458	51742	83988	68619	62446
2	Februari	61792	64040	92738	63321	61070
3	Maret	56600	60750	91071	62000	60770
4	April	51042	56857	86048	60583	60382
5	Mei	55867	51934	64012	62607	60909
6	Juni	59500	48283	49798	60495	60366
7	Juli	65375	49771	51857	63060	61013
8	Agustus	77367	68929	59464	61774	60685
9	September	84583	64000	59038	61524	60638
10	Oktober	82625	67143	52762	60464	60360
11	November	67267	64036	50774	57429	59579
12	Desember	35125	77857	69743	57238	59528

Selanjutnya penulis melanjutkan memprediksi harga cabai di kota Singkawang untuk tahun 2024 dengan metode yang sama dan membandingkan 5 *arsitektur* yang sama, dan didapatkan *arsitektur* 3-7-1 tetap menjadi *arsitektur* terbaik dengan $MSE = 0,000211701$. Pada Tabel berikut akan disajikan data awal dengan hasil prediksi 2023 dan prediksi 2024.

Tabel 11. Perbandingan Data Awal dengan Hasil Prediksi 2023 dan 2024

Data	Bulan Rata - rata	Harga 2019	Harga 2020	Harga 2021	Harga 2022	Prediksi 2023	Prediksi 2024
1	Januari	65458	51742	83988	68619	62446	60386
2	Februari	61792	64040	92738	63321	61070	60298
3	Maret	56600	60750	91071	62000	60770	60268
4	April	51042	56857	86048	60583	60382	60247
5	Mei	55867	51934	64012	62607	60909	60290
6	Juni	59500	48283	49798	60495	60366	60244
7	Juli	65375	49771	51857	63060	61013	60275
8	Agustus	77367	68929	59464	61774	60685	60271
9	September	84583	64000	59038	61524	60638	60267
10	Oktober	82625	67143	52762	60464	60360	60247
11	November	67267	64036	50774	57429	59579	60192
12	Desember	35125	77857	69743	57238	59528	60189

4. KESIMPULAN

Studi ini menunjukkan *relevansi* dan potensi metode *backpropagation* dalam prediksi harga cabai di Kota Singkawang, Indonesia. Sulitnya memprediksi *fluktuasi* harga cabai menimbulkan masalah serius bagi pasar lokal, petani, pedagang, dan konsumen, sehingga kebutuhan akan model prediksi yang lebih akurat dan andal menjadi hal yang sangat penting. Penggunaan jaringan syaraf tiruan (JST) melalui metode *backpropagation* menawarkan harapan baru untuk mengatasi ketidakpastian tersebut. Penelitian ini menemukan bahwa metode ini dapat memberikan prediksi harga cabai dengan hasil lebih baik dibandingkan metode peramalan tradisional lainnya. Metode tersebut menunjukkan potensi besar teknologi ini dalam membantu pelaku pasar cabai Singkawang dalam mengambil keputusan yang lebih tepat. Pendekatan ini tidak hanya memungkinkan kita memprediksi harga cabai dengan lebih akurat, namun juga memberikan pemahaman yang lebih baik mengenai faktor-faktor yang mempengaruhi *fluktuasi* harga.

Menggunakan cara ini, tidak hanya memberikan angka perkiraan tetapi juga memberikan konteks yang diperlukan bagi pelaku industri untuk mengambil langkah strategis yang lebih baik guna mengatasi dinamika pasar. Namun perlu diingat bahwa prakiraan harga masih berupa perkiraan dan selalu mengandung ketidakpastian. Pengembangan dan *integrasi* lebih lanjut dengan data modern dan metodologi lain diperlukan untuk meningkatkan dan menyesuaikan model yang digunakan. Penelitian lebih lanjut dapat mengarah pada *integrasi* faktor *eksternal* seperti perubahan kebijakan pemerintah, tren pasar global, dan faktor sosial yang mempengaruhi harga cabai. Pengembangan dan penyempurnaan model prediktif lebih lanjut diharapkan dapat membuat industri cabai Kota Singkawang dan pasar cabai secara keseluruhan lebih siap menghadapi *fluktuasi* harga yang tidak terduga dan mengambil keputusan yang lebih cerdas dan tepat waktu.

REFERENCES

- Aulia, A. P., Yuhandri, & Gemilang, F. A. (2021). Memprediksi Harga Komoditas Cabe Menggunakan Metode *Backpropagation* di Wilayah Kota Payakumbuh. *Jurnal KomtekInfo*, 8(1), 33–48. <https://doi.org/10.35134/komtekinfo.v8i1.96>
- Fauzi, A., Andriani, V., Febrian, A. Z., Apriyana, G., Sella, B. S., Akbar, R. A., & Fadilah, M. F. (2023). Pengaruh Meningkatnya Harga Cabai Terhadap Permintaan Dan Penawaran Di Indonesia. *Jurnal Akuntansi Dan Manajemen Bisnis*, 3(1), 73–79. <https://doi.org/10.56127/jaman.v3i1.645>
- Firdaus, M. (2021). Disparitas Harga Pangan Strategis Sebelum dan Saat Pandemi COVID-19. *Jurnal Ekonomi Indonesia*, 10(2), 107–120. <https://doi.org/10.52813/jei.v10i2.104>
- Irianti, A., Rantellinggi, P. H., Taufik, A., Zulkarnain, N., & Cokrowibowo, S. (2022). Implementation of *Backpropagation* Artificial Neural Network For Food Price Prediction in Majene Central Market. *Jurnal Teknik Informatika (JUTIF)*, 3(3), 681–688.
- Padapi, A., Mursalat, A., Haryono, I., & Fitriyah, N. (2021). Pengaruh E-Commerce Terhadap Fluktuasi Harga Dan Peningkatan Pendapatan Petani Cabai Rawit. *Jurnal AGRISEP: Kajian Masalah Sosial Ekonomi Pertanian Dan Agribisnis*, 20(1), 129–140. <https://doi.org/10.31186/jagrisep.20.01.129-140>
- Paksi, A. K., Musyaffa, N. F., & Iswari, R. D. (2023). Pandemi Covid-19: Dampak Global dan Peluang Bagi Sektor Pertanian Indonesia. *Intermestic: Journal of International Studies*, 7(2), 677–700. <https://doi.org/10.24198/intermestic.v7n2.14>
- Pradana, R. S. (2021). Penerapan Analisis Jalur Dalam Mengidentifikasi Penyebab Fluktuasi Harga Cabai Merah Di Kabupaten Aceh Jaya. *Jurnal Agrica*, 14(1), 20–32. <https://doi.org/10.31289/agrica.v14i1.4594>
- Puspita, G. R., Karyani, T., & Setiawan, I. (2023). Keberlanjutan Korporasi Petani Jagung Di Kabupaten Bandung , Jawa Barat. *Analisis Kebijakan Pertanian*, 21(1), 75–96.
- Putri, R. M., Kusdarini, & Putera, R. E. (2022). Implementasi Program Toko Tani Indonesia Center Pada Masa Pandemi Covid-19. *Musamus Journal of Public Administration*, 5(1), 19–42. <https://doi.org/10.35724/mjpa.v5i1.4369>
- Putri, S. H., Yuhandri, & Nurcahyo, G. W. (2021). Prediksi Pencapaian Target Peserta Keluarga Berencana Pasca Persalinan menggunakan Algoritma *Backpropagation* . *Jurnal Sistim Informasi Dan Teknologi*, 3(3), 176–182. <https://doi.org/10.37034/jsisfotek.v3i3.62>
- Rohman, L. L., & Andadari, R. K. (2021). Dampak Pandemi COVID-19 pada Usaha Rumah Tangga dan Strategi Bertahan. *Jurnal Penelitian Dan Pengembangan Sains Dan Humaniora*, 5(1), 82–90.
- Rozaini, N., & Silaban, S. J. (2023). Pengaruh Biaya Produksi Dan Harga Jual Terhadap Pendapatan Petani Cabai Merah Di Kecamatan Doloksanggul Kabupaten Humbang Hasundutan. *Jurnal Publikasi Sistem Informasi Dan Manajemen Bisnis*, 2(2), 128–141.
- Sen, S., Sugiarto, D., & Rochman, A. (2020). Komparasi Metode Multilayer Perceptron (MLP) dan Long Short Term Memory (LSTM) Dalam Peramalan Harga Beras. *Ultimatics: Jurnal Teknik Informatika*, 12(1), 35–41. <https://doi.org/10.31937/ti.v12i1.1572>
- Suradiradja, K. H. (2021). Algoritme Machine Learning Multi-Layer Perceptron dan Recurrent Neural Network untuk Prediksi Harga Cabai Merah Besar di Kota Tangerang. *Factor Exacta*, 14(4), 194–205.

<https://doi.org/10.30998/faktorexacta.v14i4.10376>

Waluyo, T. (2020). Penerapan Fungsi Manajemen dan Analisis Finansial Budidaya Bawang Putih (Studi Kasus Petani Bawang Putih Di Desa Cipendawa, Pacet, Cianjur- Jawa Barat). *Jurnal Ilmu Dan Budaya*, 41(72), 8573–8617.