

BAB II

TINJAUAN PUSTAKA

2.1 Landasan Teori

2.1.1 Jaringan Syaraf Tiruan (JST)

2.1.1.1 Konsep Dasar Jaringan Syaraf Tiruan

Jaringan Syaraf Tiruan (JST) merupakan salah satu representasi buatan dari otak manusia yang selalu mencoba untuk mensimulasikan proses pembelajaran otak manusia. JST dibuat sebagai model matematika umum dari kognisi manusia. Ini didasarkan pada asumsi bahwa pemrosesan informasi terjadi pada elemen sederhana yang disebut neuron. Sinyal mengalir di antara sel-sel saraf melalui koneksi, dan setiap koneksi memiliki bobot yang sesuai. Fungsi aktivasi akan dilakukan pada setiap sel saraf dari sinyal penjumlahan terbobot yang masuk untuk menentukan sinyal keluarannya (Lesnussa, Sinay, dan Idah 2017). JST ditentukan oleh 3 hal:

1. Pola hubungan antar neuron (disebut arsitektur jaringan)
2. Metode untuk menentukan bobot penghubung
3. Fungsi aktivasi.

2.1.1.2 Arsitektur jaringan syaraf tiruan

Jaringan syaraf tiruan dirancang menggunakan aturan umum, di mana semua model jaringan memiliki konsep dasar yang sama. Arsitektur jaringan akan menentukan keberhasilan tujuan yang ingin dicapai, karena tidak semua masalah

dapat diselesaikan dengan arsitektur yang sama (Zola 2018). JST memiliki beberapa arsitektur yang sering digunakan pada aplikasi. Arsitektur tersebut antara lain (Lesnussa dkk. 2017)

1. Jaringan Lapisan Tunggal (*Single Layer Network*) terdiri dari 1 lapisan *input* dan 1 lapisan *output*, setiap neuron pada lapisan *input* selalu terhubung dengan setiap *neuron* pada lapisan *output*. Jaringan ini hanya menerima *input* dan memprosesnya langsung menjadi *output* tanpa melalui lapisan tersembunyi.
2. Jaringan Banyak Lapisan (*Multilayer Net*) Jaringan dengan banyak lapisan memiliki karakteristik tertentu, yaitu memiliki tiga jenis lapisan, yaitu lapisan *input*, lapisan *output*, dan lapisan tersembunyi. Jaringan *multi-layer* dapat memecahkan masalah yang lebih kompleks daripada jaringan *single-layer*. Namun, proses pelatihan seringkali memakan waktu lama.
3. Jaringan Lapisan Kompetitif (*Competitive Layer*) Pada jaringan ini setiap kumpulan *neuron* akan bersaing untuk mendapatkan hak menjadi aktif. LVQ merupakan salah satu contoh algoritma yang menggunakan jaringan ini.

2.1.1.3 Fungsi Aktivasi

Fungsi aktivasi digunakan untuk menentukan keluaran *neuron*, keluaran menggambarkan hubungan antara tingkat aktivasi internal (fungsi *summation*), yang dapat berupa linier atau non-linier. Beberapa fungsi aktivasi jaringan syaraf tiruan meliputi (Hasan, Kusriani, dan Fatta 2019):

a. Fungsi *summation*

Fungsi yang digunakan untuk mencari rata-rata bobot dari semua elemen input.

$$S_i = \sum_{j=1}^N W_{ij} \cdot X_j \quad (2.1)$$

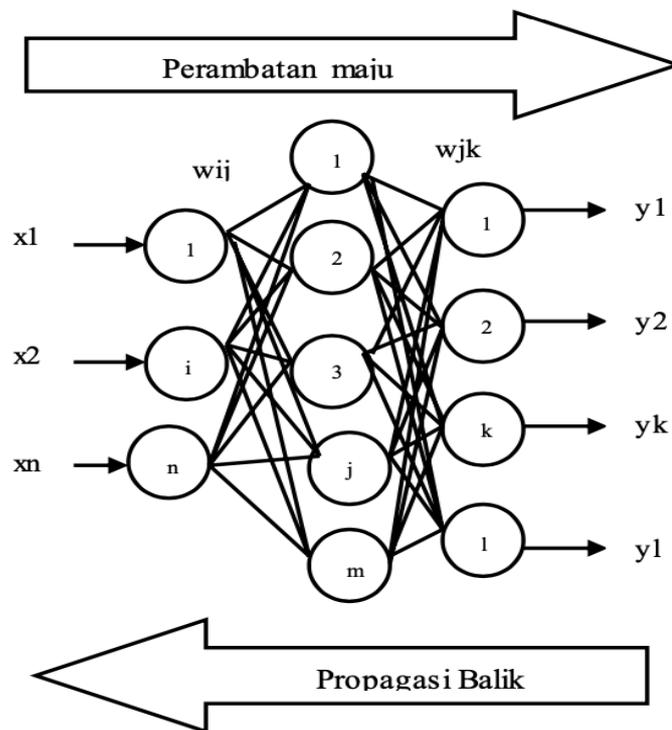
Bentuk sederhananya adalah dengan mengalikan setiap nilai input (X_j) dengan bobotnya (W_{ij}) dan menjumlahkannya disebut penjumlahan berbobot atau S_i).

b. *Sum Square Error (SSE)* dan *Root Mean Square Error (RMSE)*

Perhitungan kesalahan merupakan suatu pengukuran bagaimana jaringan dapat belajar dengan baik. Kesalahan pada keluaran jaringan adalah selisih antara keluaran aktual (keluaran saat ini) dan keluaran yang diharapkan (keluaran yang diharapkan), dan selisih antara keduanya biasanya ditentukan dengan menggunakan perhitungan persamaan.

2.1.2 *Backpropagation*

Backpropagation adalah metode pembelajaran jaringan JST yang paling umum digunakan. Metode ini membandingkan nilai prediksi jaringan dengan setiap contoh melalui proses iteratif menggunakan sekumpulan data sampel (data latih). Bobot hubungan dalam jaringan dimodifikasi pada setiap proses untuk meminimalkan nilai *Mean Square Error (MSE)* antara nilai prediksi jaringan dan nilai sebenarnya. Modifikasi hubungan JST dilakukan secara terbalik, dari lapisan keluaran ke lapisan pertama lapisan tersembunyi, sehingga metode ini disebut *backpropagation* atau propagasi balik (Novita 2016).



Gambar 2. 1 Arsitektur JST *Backpropagation*

Berdasarkan Gambar 2.2, *Backpropagation* merupakan algoritma dengan *supervised learning*. Disebut *supervised learning* karena dalam teknik pembelajaran dilakukan dengan membuat fungsi dari data latih untuk mempelajari fungsi pemetaan dari *input* ke *output*, sehingga memiliki tujuan (*Goal*) untuk memperkirakan fungsi pemetaannya, sehingga ketika memiliki *input* baru, algoritma dapat memprediksi *output* dari *input* tersebut. (Agus Perdana Windarto dkk. 2019).

2.1.3 Optimasi *Adabound*

Adabound adalah optimasi varian baru dari Adam dan AMSGrad. Optimasi ini diciptakan untuk dapat menerapkan batas dinamis pada kecepatan pembelajaran

untuk mencapai tujuan transisi dari optimasi adaptif ke optimasi SGD (Luo dkk. 2019). Keduanya dapat mengeliminasi kesenjangan generalisasi tetapi juga mempertahankan kecepatan pembelajaran yang lebih tinggi dalam proses pelatihan awal. Detail optimasi *Adabound* dirumuskan sebagai berikut:

$$g_t = \nabla f_t(x_t) \quad (2.2)$$

$$m_t = \beta_{1t}m_{t-1} + (1 - \beta_{1t})g_t \quad (2.2)$$

$$v_t = \beta_2v_{t-1} + (1 - \beta_2)g_t^2 \quad (2.3)$$

$$\eta_t = \frac{\hat{\eta}_t}{\sqrt{t}} \quad (2.4)$$

Asumsi

$$\hat{\eta}_t = \text{Clip}(\alpha/\sqrt{v_t}, \eta_l(t), \eta_u(t)) \quad (2.5)$$

$$V_t = \text{diag}(v_t) \quad (2.6)$$

$$x_{t+1} = \Pi_{\mathcal{F}, \text{diag}(\eta_t^{-1})}(x_t - \eta_t \odot m_t) \quad (2.7)$$

Dimana β_1 dan β_2 merupakan nilai dari momentum dan secara bawaan bernilai 0,9 dan 0,99. $\text{Clip}(\alpha/\sqrt{v_t}, \eta_l, \eta_u)$ merepresentasikan learning rate α/V_t dipotong, lalu $\hat{\eta}_t$ dibatasi kedalam $[\eta_l, \eta_u]$, yang mana dapat menghentikan lonjakan gradient. Hypermeter η_l dan η_u keduanya diset sebagai fungsi dari t bukan sebagai batas atas dan batas bawah yang konstan, dan parameternya diperbaharui menggunakan formula 2.7, dimana *learning rate* diperbaharui menggunakan fungsi t , dan perbedaan antara batas atas dan batas bawah menjadi lebih kecil.

2.1.4 *Root Mean Square Error (RMSE)*

$$RMSE = \sqrt{\frac{\sum(\text{aktual}-\text{prediksi})^2}{n}} \quad (2.8)$$

Root Mean Square Error (RMSE) adalah penjumlahan kuadrat error atau selisih antara nilai aktual dengan nilai prediksi, kemudian membagi jumlah tersebut dengan banyaknya waktu data peramalan dan kemudian menarik akarnya. Jika nilai RMSE semakin kecil maka estimasi model atau variabel tersebut semakin baik (Dasuki 2020).

2.1.5 *Mean Absolute Error (MAE)*

Mean Absolute Error (MAE) adalah suatu metode yang digunakan untuk mengukur keakuratan suatu prediksi dengan cara merata-ratakan kesalahan yang diperkirakan (nilai kesalahan mutlak). Metode ini menggunakan sejumlah kesalahan sederhana dalam evaluasinya. Metode MAE ini dapat dihitung dengan rumus berikut:

$$MAE = \frac{\sum|y_1-y'|}{n} \quad (2.9)$$

Keterangan:

y_1 = Nilai sebenarnya

y' = Nilai prediksi

n = jumlah keseluruhan data

2.1.6 Mean Absolute Percentage Error (MAPE)

Mean Absolute Percentage Error (MAPE) merupakan perhitungan yang menggunakan kesalahan absolut pada setiap periode dibagi dengan nilai yang diamati yang terbukti untuk periode tersebut. Kemudian, rata-ratakan persentase tetap tersebut. Pendekatan ini berguna ketika ukuran atau ukuran variabel prediksi signifikan dalam mengevaluasi keakuratan prediksi. MAPE menunjukkan seberapa besar kesalahan dalam memprediksi dibandingkan dengan nilai sebenarnya (Khair dkk. 2017).

$$MAPE = \frac{\sum \frac{|y_1 - y'|}{y_1}}{n} \times 100\% \quad (2.10)$$

Keterangan:

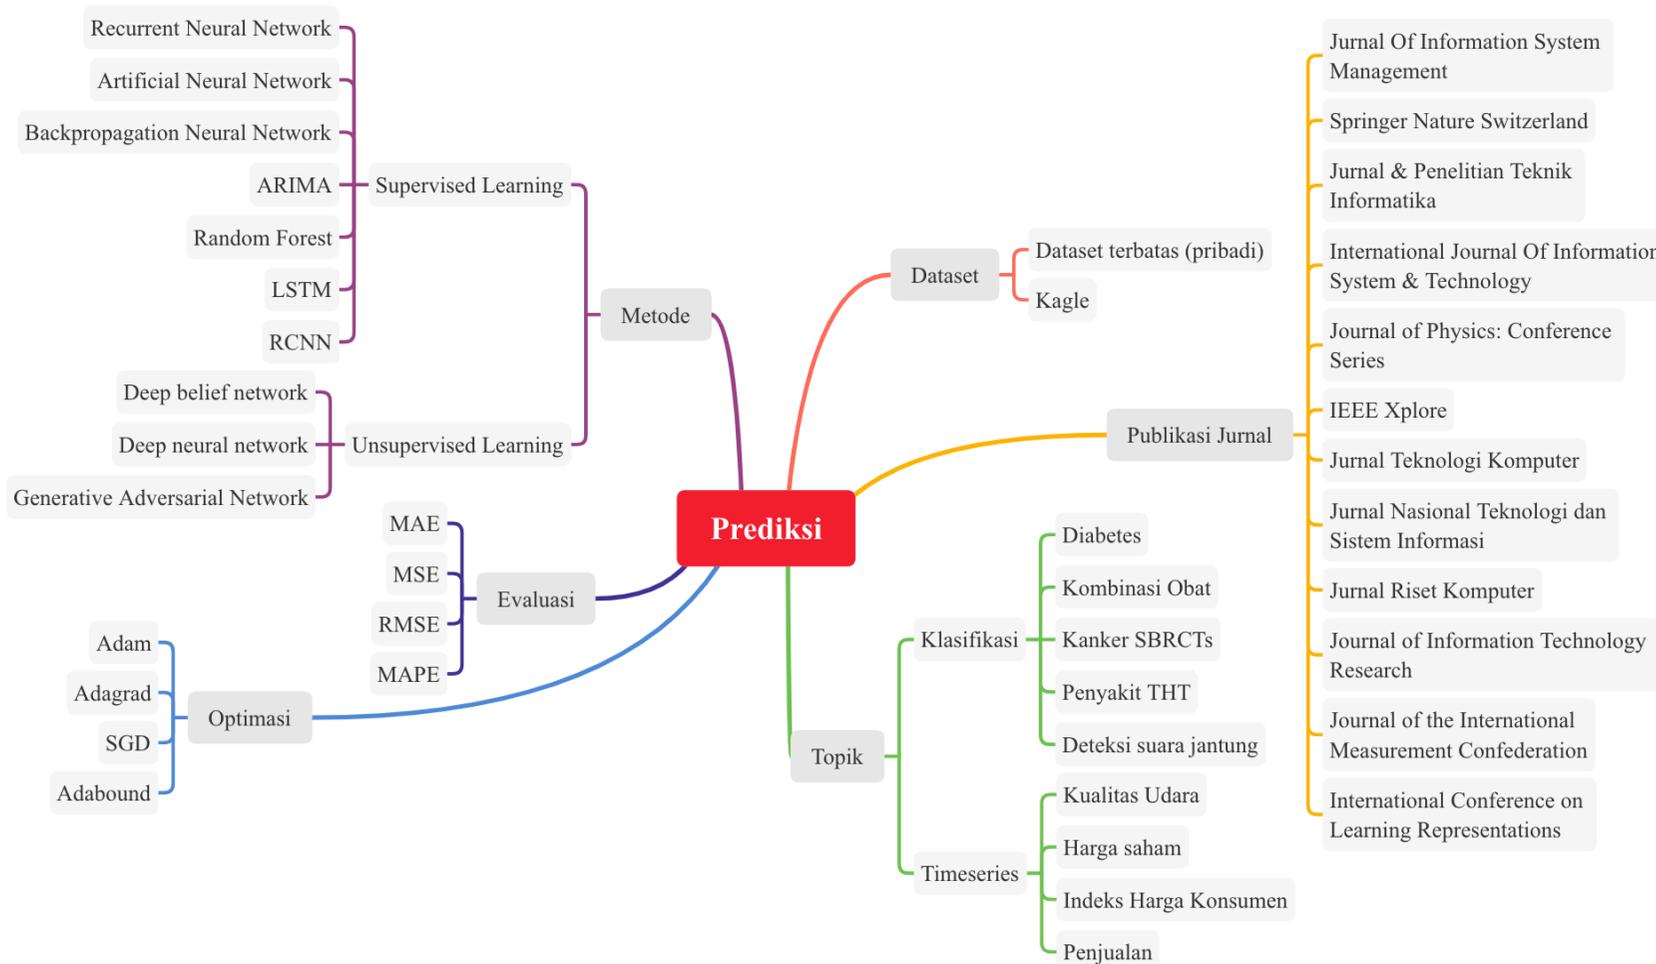
y_1 = Nilai sebenarnya

y' = Nilai prediksi

n = jumlah keseluruhan data

2.2 Penelitian Terkait

Literatur yang digunakan dalam penelitian ini berasal dari buku, jurnal, dan artikel yang berhubungan dengan topik penelitian yaitu mengenai *machine learning*. Hasil eksplorasi literatur dapat dilihat pada Gambar 2.2 yang merupakan peta literatur (*literature map*).



Gambar 2. 2 Peta Literatur

Penelitian terkait JST *backpropagation* dan optimasi Adabound terkait pengembangan model, metode, maupun solusi yang ditawarkan atas permasalahan yang diteliti, dituangkan pada Tabel 2.1.

Tabel 2. 1 Matriks Penelitian Terkait

No	Judul	Penulis	Tujuan	Metode Penelitian	Hasil
1.	Analysis Accuracy of Artificial Neural Network Using Backpropagation Algorithm in Predicting Process (Forecasting)	(Siregar dan Wanto 2017)	Menganalisis tingkat akurasi jaringan syaraf tiruan dengan metode backpropagation untuk memprediksi indeks pembangunan manusia di provinsi Sumatera utara.	<ol style="list-style-type: none"> 1. Pengumpulan data & studi literatur 2. Menentukan permasalahan 3. Pre-process 4. Menentukan pola 5. Pengujian hasil Pre-processing data 6. Prediksi 7. Evaluasi 	Penelitian ini berhasil menerapkan ANN metode <i>Backpropagation</i> untuk memprediksi indeks pembangunan manusia di provinsi Sumatera Utara yang menghasilkan tingkat akurasi paling tinggi 100% dan paling rendah 82%.
2.	Penerapan Prediksi Produksi Padi Menggunakan Artificial Neural Network Algoritma Backpropagation	(Putra dan Ulfa Walmi 2020)	Menentukan banyak neuron dan jumlah layer yang diperlukan untuk prediksi hasil produksi padi	<ol style="list-style-type: none"> 1. Pengumpulan data 2. Pre-processing data 3. Proses prediksi 4. Pengujian akurasi 5. implementasi 	Penerapan metode ANN metode <i>Backpropagation</i> untuk memprediksi hasil produksi padi penelitian ini berhasil memperoleh akurasi mencapai 88,14%.

No	Judul	Penulis	Tujuan	Metode Penelitian	Hasil
3.	Peramalan Penjualan Semen Menggunakan Backpropagation Neural Network Dan Recurrent Neural Network	(Aisyah Fany Achmalia , Walid 2020)	Menentukan pemodelan Backpropagation Neural Network untuk peramalan penjualan semen	<ol style="list-style-type: none"> 1. Identifikasi 2. Studi Pustaka 3. Pengumpulan data 4. Penentuan input dan target jaringan 5. Membagi data 6. Normalisasi 7. Membangun jaringan 8. Training dan testing 9. Denormalisasi 10. Menentukan model terbaik 11. Uji kesesuaian model 12. Peramalan 13. Validasi akurasi 14. Kesimpulan 	Penelitian ini mengimplementasikan Jaringan Syaraf Tiruan Metode Backpropagation pada peramalan penjualan semen, diperoleh akurasi sebesar 87,9727% dengan model BPNN (9-5-1)
4.	Jaringan Syaraf Tiruan Backpropagation Untuk Peramalan Penjualan Produk	(Welnof 2020)	Meramalkan penjualan pada periode tertentu untuk masa mendatang.	<ol style="list-style-type: none"> 1. Analisis dan Identifikasi 2. Pengumpulan data 3. Analisis Data 4. Peralaman 5. Menentukan model 6. Pengujian 7. Kesimpulan 	Jaringan Syaraf Tiruan Metode backpropagation mampu untuk meramalkan penjualan.

No	Judul	Penulis	Tujuan	Metode Penelitian	Hasil
5.	Implementasi Metode <i>Backpropagation</i> Untuk Memprediksi Penjualan <i>Furniture</i> Pada Pt. Indah Jaya Medan	(Raja dan Sinurat 2018)	Memprediksi penjualan furniture untuk memaksimalkan penjualan.	<ol style="list-style-type: none"> 1. Pengumpulan data 2. Normalisasi 3. Training data 4. Testing data 5. Validasi 6. Implementasi 7. kesimpulan 	<p>Jaringan Syaraf Tiruan metode backpropagation dapat diterapkan dalam menganalisa prediksi penjualan furniture berdasarkan hasil penjualan dari tahun sebelumnya sehingga penerapan pola yang dikeluarkan jaringan dapat memenuhi pola yang diinginkan.</p> <p>Jaringan Syaraf Tiruan dengan metode backpropagation mampu menentukan atau memprediksi penjualan furniture.</p>
6.	<i>Implementation of Artificial Neural Networks to Predict Monthly Target Receiving Section in Pt. Indako Trading</i>	(Firmansyah dan Manurung 2020)	Memprediksi penjualan spare part motor di PT. Indako Trading Coy	<ol style="list-style-type: none"> 1. Studi Pustaka 2. Identifikasi masalah 3. Analisis Kebutuhan 4. Pengumpulan Data 5. Perancangan dan implementasi 	<p>Penggunaan Neural Network metode backpropagation mampu memprediksi data penjualan dengan tingkat akurasi 67%.</p>

No	Judul	Penulis	Tujuan	Metode Penelitian	Hasil
	<i>Coy using Backpropagation Method.</i>			6. Pengujian dan analisis 7. Kesimpulan dan saran	
7.	<i>An Application of Backpropagation Neural Network for Sales Forecasting Rice Milling Unit</i>	(Aritonang dan Sihombing 2019)	Memprediksi penjualan beras untuk mengetahui persediaan padi yang dibutuhkan.	1. Pengumpulan data 2. Pemrosesan data 3. Peramalan 4. Analisis	Dengan menggunakan backpropagation neural network menghasilkan nilai MSE 0.00099715.
8.	Implementasi Jaringan Syaraf Tiruan (JST) Untuk Memprediksi Jumlah Penjualan Gas 3Kg Menggunakan Metode Backpropagation	(Tambunan, Hartama, dan Gunawan 2021)	Memprediksi penjualan gas 3 kg untuk upaya memenuhi kuota permintaan pelanggan.	1. Pengumpulan data 2. Analisis data 3. Pra process 4. Menentukan pola 5. Menguji pengolahan data 6. Memprediksi 7. Selesai	Jaringan syaraf tiruan dengan metode backpropagation dapat diterapkan untuk memprediksi penjualan gas 3kg, dengan arsitektur terbaik adalah 2-20-1 dengan tingkat akurasi 90% dengan MSE pelatihan 0,0010000150, MSE Pengujian 0,0263081322 dan 1366.

No	Judul	Penulis	Tujuan	Metode Penelitian	Hasil
9.	Peramalan Penjualan Pada Toko Retail Menggunakan Algoritma Backpropagation Neural Network	(Yanto dkk. 2018)	Untuk membantu pengusaha retail dalam menentukan berapa pengadaan barang yang harus disediakan, dikarenakan banyak barang yang menumpuk tidak terjual.	<ol style="list-style-type: none"> 1. Pengumpulan data 2. Transformasi data 3. Training data 4. Pengujian 5. Validasi 6. Kesimpulan 	Algoritma Backpropagation mampu memprediksi perkiraan penjualan toko ritel dengan mengacu pada data penjualan yang terjadi di toko ritel. Hasil prediksi yang sudah didapat ini memiliki total kesalahan (Total Error) sebesar = 3.57 %.
10.	Prediksi Jumlah Penjualan Produk di PT Ramayana Pematangsiantar Menggunakan Metode JST Backpropagation	(Syafiq dkk. 2020)	Untuk meningkatkan jumlah penjualan produk-produk agar tidak mengalami kerugian yang besar bagi perusahaan.	<ol style="list-style-type: none"> 1. Mengumpulkan data dan studi Pustaka 2. Identifikasi masalah 3. Pra proses 4. Menentukan pola 5. Menguji hasil pengolahan data 6. Memprediksi 7. Mengevaluasi akhir 	Penelitian ini menghasilkan bahwa arsitektur yang terbaik untuk memprediksi adalah 3-35-1 dengan akurasi 92%, MSE training sebesar 0.00099689.
11.	<i>Prediction of Photovoltaic Power Generation Based On General</i>	(Zhong dkk. 2018)	Penelitian ini bertujuan untuk meramalkan daya	<ol style="list-style-type: none"> 1. Melakukan analisis korelasi berdasarkan metode koefisien korelasi pearson 	Penelitian ini membandingkan dua model yang dirancang, diantaranya backpropagation neural

No	Judul	Penulis	Tujuan	Metode Penelitian	Hasil
	<i>Regression and Back Propagation Neural Network</i>		yang dihasilkan dari fotovoltaic.	<ol style="list-style-type: none"> 2. Klasifikasi data cuaca menggunakan Learning Vector Quantization Neural Network 3. Melakukan prediksi daya Fotovoltaic dengan metode general regression dan backpropagation neural network 	network dengan general regression. Berdasarkan analisis peneliti bahwa hasil membuktikan backpropagation neural network memiliki prediksi lebih baik jika dibandingkan dengan general regression.
12.	<i>MLP Back Propagation Artificial Neural Network for Solar Resource Forecasting in Equatorial Areas</i>	(Lima dkk. 2018)	Penelitian ini bertujuan untuk memprediksi radiasi matahari untuk digunakan dalam memperkirakan listrik yang dihasilkan dari pembangkit listrik berbasis sel surya.	<ol style="list-style-type: none"> 1. Mengumpulkan data 2. Pembuatan dataset 3. Pembuatan model 4. Prediksi radiasi matahari 4. Validasi error prediksi 	MLP Backpropagation Neural Network yang digunakan pada penelitian ini mampu memprediksi radiasi matahari dengan menggunakan data 1 jam sebelumnya. Jaringan terbaik pada penelitian ini dapat memprediksi dengan tingkat eror paling tinggi 5% dengan 41,9% dari data prediksi, <i>error</i> dibawah 10% dengan 58.7% data

No	Judul	Penulis	Tujuan	Metode Penelitian	Hasil
					prediksi, dan error dibawah 15% dengan 68,6% data prediksi.
13.	<i>Model of Artificial Neural Network in Predictions of Corn Productivity in an Effort to Overcome Imports in Indonesia</i>	(Wanto dkk. 2019)	Mengembangkan model untuk memprediksi tingkat produksi jagung dalam meminimalkan jumlah impor jagung.	<ol style="list-style-type: none"> 1. Mengumpulkan data 2. Memisahkan data 3. Menentukan struktur jaringan 4. Memilih algoritma pelatihan 5. Inisialisasi parameter jaringan 6. Menentukan data input 7. Pelatihan 8. Pengujian 9. Implementasi dar Artificial Neural Network 	Tingkat akurasi tertinggi didapat dengan struktur jaringan 5-25-1 dan jumlah epoch pelatihan sebanyak 5972 menghasilkan tingkat error 0.00992433.
14.	<i>Accuracy Level of Backpropagation Algorithm to Predict Livestock Population of Simalungun</i>	(Purba dkk. 2019)	Menganalisis arsitektur terbaik untuk memprediksi jumlah populasi ternak berdasarkan jenis ternak di	<ol style="list-style-type: none"> 1. Mengumpulkan data 2. Mengidentifikasi masalah 3. Pembuatan dataset 4. Normalisasi data 5. Membuat model jaringan 	Arsitektur terbaik yang dihasilkan pada penelitian ini yaitu dengan struktur jaringan 3-7-1 dengan level MSE 0.000997672

No	Judul	Penulis	Tujuan	Metode Penelitian	Hasil
	<i>Regency in Indonesia</i>		Kabupaten Simalungun Indonesia.	6. Pelatihan 7. Pengujian 8. Kesimpulan	dibanding dengan 4 arsitektur lainnya.
15.	<i>Adaptive Gradient Method With Dynamic Bound Of Learning Rate</i>	(Luo dkk. 2019)	Menciptakan optimasi varian baru dari ADAM dan AMSGRAD yang disebut ADABOUND dan AMSBOUND, dimana Keduanya menggunakan batasan yg dinamis dalam pembelajaran agar menghasilkan transisi yg bertahap dari metode adaptif ke metode SGD dan membuktikan konvergensi secara teori.		Berdasarkan eksperimen yang dilakukan bahwa varian baru ini dapat mengeliminasi sebuah gap generalisasi diantara adaptive methods dan SDG dan mempertahankan kecepatan pembelajaran yang tinggi di awal dalam pelatihan di satu waktu.

No	Judul	Penulis	Tujuan	Metode Penelitian	Hasil
16.	<i>Random convolutional neural network structure: an intelligent health monitoring scheme for diesel engines</i>	(Wang, Chen, dan Guan 2021)	Penelitian ini bertujuan membuat struktur jaringan dengan random convolutional neural network (RCNN) dan menggunakan optimasi Adabound yang digunakan untuk mengakselerasi pelatihan pada struktur jaringan untuk menciptakan monitoring kesehatan cerdas dari mesin diesel.	<ol style="list-style-type: none"> 1. Pengumpulan data 2. Transformasi dataset gambar 3. Pemisahan dataset menjadi data pelatihan dan data testing 4. Pembuatan struktur jaringan 5. Pelatihan 6. Pengujian 7. Kesimpulan 	Struktur jaringan menggunakan RCNN dapat meningkatkan akurasi dan stabilitas klasifikasi dibanding dengan CNN standar, dan penggunaan optimasi Adabound dan Dropout dapat mengurangi waktu komputasi.

No	Peneliti	Objek Penelitian	Algoritma										Optimasi			Hasil		
			JST	Arima	Backpropagation	SVR	Random Forest	LSTM	Recurman NN	Convolutional NN	Monte Carlo	RCNN	Adam	SGD	Adabound	Akurasi	Kecepatan	
8.	(Pandey, Rastogi, dan Singh 2020)	Harga Mobil					V										V	
9.	(Welnof 2020)	Penjualan Produk	V		V												V	
10.	(Arisena 2020)	Penjualan Mobil		V													V	
11.	(Bias Yulisa Geni, Julius Santony 2019)	Penjualan Cat									V						V	
12.	(Wang dkk. 2021)	Monitoring Kesehatan Mesin Disel										V	V	V	V		V	V
13.	(Rifki, 2022)	Penjualan Minuman Ringan	V		V											V	V	V

Tabel 2.2 merupakan hasil pemetaan penelitian yang telah dilakukan sebelumnya terkait prediksi dan menampilkan kebaruan dari penelitian yang akan dilakukan.