



Usulan Perencanaan Persediaan Produk FMCG Menggunakan Metode Algoritma Apriori dan Jaringan Syaraf Tiruan (JST) pada PT Borwita Indah

Bayu Triadi Putra¹, Zeny Fatimah Hunusalela², Ririn Regiana Dwi Satya³

^{1,2,3} Fakultas Teknik dan Ilmu Komputer, Jurusan Teknik Industri, Universitas Indraprasta PGRI
Jl. Nangka Raya No.58 C, Daerah Khusus Ibukota Jakarta 12530
Email: bayutriadiputra@gmail.com, zeny.fh86@gmail.com, ririn.regiana86@gmail.com

Abstract

The problem faced by PT Borwita Indah is the occurrence of overstock and understock on FMCG products. This study aims to determine the inventory planning of FMCG products with related factors, namely sales results, stock of finished goods, and to be able to predict accurately so that there is no buildup of products in the warehouse. This research using the apriori algorithm for data collection with associative rules which is carried out through support and confidence calculation mechanisms and artificial neural networks for forecasting methods which have a fairly low data error rate and are good enough in the generalization process so that this model is able to predict timeseries data for several time periods for future. Itemset data pattern obtained resulted in a level of confidence in Head&Shoulders with Pantene 90.9%, and a level of confidence in Pantene with Head&Shoulders 90.9%. Meanwhile, the level of confidence for Vicks with Head&Shoulders reaches 100%. Forecasting results for the next 12 periods for each Pantene, Head&Shoulders, and Vicks product have a fluctuating forecasting trend so that safety stock can be taken into account. The amount of safety stock that must be in the company is 504 pcs of Pantene per day, 49 pcs of Head&Shoulders per day, 35 pcs of Vicks. It is hoped that with this research the company can carry out optimal product inventory control.

Keywords: Supply, Forecasting, Demand, Apriori, Artificial Neural Networks

Abstrak

Permasalahan yang dihadapi PT Borwita Indah yaitu terjadinya *overstock* maupun *understock* pada produk FMCG. Penelitian ini bertujuan untuk mengetahui perencanaan persediaan produk FMCG dengan faktor terkait yaitu hasil penjualan, stok barang jadi, serta dapat memprediksi dengan tepat sehingga tidak terjadinya penumpukan produk di gudang. Penelitian ini menggunakan algoritma apriori untuk pengambilan data dengan aturan asosiatif (*association rule*) yang dilakukan melalui mekanisme perhitungan *support* dan *confidence* dan jaringan saraf tiruan untuk metode peramalan yang memiliki tingkat *error* data yang cukup rendah dan cukup baik dalam proses generalisasi sehingga model ini mampu untuk meramalkan data *time series* untuk beberapa periode waktu ke depan. Itemset data *pattern* yang diperoleh menghasilkan tingkat kepercayaan pada produk Head&Shoulders dengan produk Pantene sebesar 90,9%, serta tingkat kepercayaan Pantene dengan produk Head&Shoulders sebesar 90,9%. Sementara itu, tingkat kepercayaan untuk produk Vicks dengan Head&Shoulders mencapai 100%. Hasil peramalan untuk 12 periode ke depan untuk masing-masing produk Pantene, Head&Shoulders, dan Vicks memiliki trend peramalan yang fluktuatif sehingga dapat diperhitungkan *safety stock*nya. Jumlah *safety stock* yang harus ada pada perusahaan adalah 504 pcs produk Pantene per hari, produk Head&Shoulders 49 pcs per harinya, produk Vicks 35 pcs. Diharapkan dengan adanya penelitian ini perusahaan dapat melakukan pengendalian persediaan produk yang optimal.

Kata kunci: Persediaan, Peramalan, Permintaan, Apriori, Jaringan Syaraf Tiruan

Pendahuluan

Pada era modern ini, perkembangan dunia industri retail sangatlah ketat dan kompetitif. Perusahaan harus memiliki kemampuan kinerja yang tinggi agar memberikan hasil yang maksimal untuk para *customer*, juga memberikan kecepatan barang sampai hingga ketersediaan produk dan dapat menguasai pasar dengan baik. Dengan demikian, perusahaan dituntut dapat mengendalikan persediaan barang dengan baik agar dapat mengoptimalkan penjualan dan mendapatkan keuntungan (Bilaffayza et al., 2023).

Perusahaan harus mempersiapkan perencanaan yang akurat dalam mengoptimalkan proses persediaan produk. Perencanaan dapat membantu perusahaan dalam memperkirakan kejadian yang akan terjadi dimasa mendatang sehingga tujuan perusahaan dapat tercapai. Peramalan permintaan merupakan salah satu strategi yang dapat dilakukan, tidak hanya menentukan perencanaan penjualan, peramalan juga dapat digunakan untuk memperkirakan persediaan agar tidak menumpuk pada gudang. Perencanaan dapat menggunakan data historis penjualan yaitu data terdahulu untuk melakukan perencanaan masa mendatang. (Amalia et al., 2020)

Persediaan memegang peranan yang sangat penting dalam menunjang operasi (kegiatan) pada perusahaan atau organisasi tersebut. Perusahaan retail FMCG memiliki persediaan dengan bentuk, nilai, dan kepentingan yang berbeda-beda. Perusahaan yang relatif besar memiliki nilai persediaan yang tinggi hingga bisa mencapai miliaran rupiah setiap saat. Persediaan membutuhkan tempat penyimpanan yang luas, sehingga berakibat terjadinya biaya-biaya penyimpanan yang tinggi (Nasution, A. H., & Prasetyawan, 2008).

PT Borwita Indah adalah perusahaan yang berpengalaman puluhan tahun di bidang distribusi dan logistik, dan memberikan solusi bagi para pelaku bisnis yang ingin menjual produknya melalui *e-commerce*. Adapun ORBIZ adalah solusi *e-commerce enabler* dan logistik dengan sistem yang dapat disesuaikan dengan kebutuhan bisnis dari PT Borwita Indah. Perusahaan ini menggunakan sistem pesanan (*make to stock*). Persediaan produk *consumer goods* dilakukan hanya berdasarkan permintaan pelanggan. Namun, permintaan sering kali mengalami perubahan yang cukup

signifikan sehingga terjadi fluktuasi dari sisi customer yang meminta produk secara tidak konsisten dan menjadikan persediaan menumpuk dalam gudang. Permintaan produk P&G ditunjukkan pada tabel permintaan periode Juni 2021-Mei 2023 yaitu Tabel 1.

Tabel 1. Data persediaan produk P&G pada PT Borwita Indah

Periode (Tahun)	Periode (Bulan)	Persediaan	Permintaan	Selisih
2021	Juni	2022	904	1118
	Juli	2088	1338	750
	Agu	2526	1454	1072
	Sept	2609	1341	1268
	Okt	5696	1425	4271
	Nov	1386	396	990
	Des	2091	1453	638
	Jan	2039	644	1395
	Feb	2582	754	1828
	Maret	2704	967	1737
	April	2747	1290	1457
	Mei	3162	3508	-346
2022	Juni	3078	1650	1428
	Juli	3291	1867	1424
	Agu	4883	3783	1100
	Sept	2687	1549	1138
	Okt	5283	782	4501
	Nov	2073	559	1514
	Des	2311	1211	1100
	Jan	2499	585	1914
	Feb	2498	812	1686
	Maret	2794	655	2139
	April	2707	1853	854
	Mei	3367	2176	1191

Sumber: Data persediaan PT Borwita Indah

Tabel 1 merupakan total keseleruhan dari beberapa produk P&G meliputi Pantene, Head&Shoulders, Rejoice, Vicks, Downy, Olay. Menandakan bahwa adanya penumpukan persediaan. Hal tersebut dilihat dari selisih dari persediaan dengan permintaan. Selisih yang besar berakibat penumpukan yang disebabkan karena sistem perencanaan PO (*Purchase Order*) yang kurang efektif. Produk tersebut merupakan produk jadi yang akan didistribusi langsung ke *customer*.

Apabila persediaan menumpuk dalam gudang dapat menyebabkan kerugian bagi perusahaan karena terjadinya pemborosan yang tidak sesuai dengan perencanaan, kurangnya persediaan juga dapat menyebabkan kerugian karena perusahaan

bisa mengalami keterlambatan pengiriman kepada *customer*.

Permintaan yang fluktuatif dianalisis dengan menggunakan metode algoritma apriori dan Jaringan Syaraf Tiruan (JST) Backpropagation, yang menghubungkan item-item dalam data penjualan. Dari kedua metode tersebut akan meramalkan permintaan dan mengatur persediaan produk konsumen agar dapat mengidentifikasi pola persediaan yang optimal. *Backpropagation* merupakan algoritma pembelajaran yang terawasi dan biasanya digunakan oleh *perceptron* dengan banyak lapisan untuk mengubah bobot-bobot yang terhubung dengan neuron-neuron yang ada pada lapisan tersembunyinya (Sri Kusumadewi, 2004).

Menurut (Kusrini & Luthfi, 2009) algoritma apriori adalah jenis aturan asosiasi pada data mining. Algoritma ini ditujukan untuk mencari kombinasi itemset yang mempunyai suatu nilai keseringan tertentu sesuai kriteria atau filter yang diinginkan. Penerapan algoritma apriori, membantu dalam membentuk kandidat kombinasi item yang mungkin terjadi, kemudian dilakukan pengujian apakah kombinasi tersebut memenuhi parameter *support* dan *confidence* minimum yang merupakan nilai ambang batas yang diberikan oleh pengguna. (Kurniawan, 2022) Persediaan pengaman (*safety stock*) merupakan jumlah persediaan tambahan yang disimpan oleh sebuah perusahaan atau organisasi sebagai langkah pengamanan untuk mengatasi ketidakpastian dalam permintaan pelanggan atau dalam pasokan bahan baku. *Safety stock* bertujuan untuk melindungi perusahaan dari risiko kekurangan persediaan yang dapat menyebabkan masalah seperti kehilangan penjualan, penurunan kepuasan pelanggan, atau gangguan dalam proses produksi.

Penelitian tentang algoritma apriori dan JST sudah banyak dilakukan sebelumnya. Penelitian-penelitian lain yang berhubungan dengan algoritma apriori dan JST yang dipakai sebagai referensi dalam penelitian ini antara lain adalah sebagai berikut:

1. (Badrul et al., 2016) melakukan penelitian dengan judul "Algoritma Asosiasi dengan Algoritma Apriori untuk Analisa Data Penjualan". Penelitian Badrul et al. ini melakukan analisa data penjualan menggunakan algoritma apriori dengan cara mengurangi jumlah transaksi

(*transaction reduction*) yang jumlah item pertransaksinya tidak memenuhi nilai batas yang ditentukan. Pengurangan transaksi tersebut berdampak pada efisiensi waktu yang lebih cepat saat *scanning database*.

2. (Mira Febrina, Faula Arina, 2013) Melakukan penelitian dengan judul "Peramalan Jumlah Permintaan Produksi Menggunakan Jaringan Saraf Tiruan Algoritma Backpropagation". Penelitian Mira Febrina dan Faula Arina menggunakan JST jaringan saraf tiruan dengan 3 input layer, 1 output layer, dan 1 hidden layer dan belum mendapatkan hasil yang regresi MSE yang optimal.

Penelitian ini bertujuan untuk mengetahui gambaran perencanaan persediaan produk *consumer goods* PT Borwita Indah dengan faktor terkait yaitu hasil penjualan, stok barang jadi, serta dapat memprediksi dengan tepat sehingga tidak terjadinya penumpukan produk di gudang dan akan menghasilkan informasi yang dapat menjadi dasar pengambilan keputusan oleh pihak PT Borwita Indah.

Metodologi

Identifikasi Metodologi Penelitian

Penelitian ini dilakukan dengan melalui beberapa tahapan yaitu melakukan studi literatur pada persediaan barang jadi, merumuskan masalah yang ada pada tempat penelitian, kemudian menentukan tujuan penelitian, pengumpulan data menggunakan data primer yaitu berasal dari data perusahaan mengenai data persediaan produk dan data permintaan aktual produk. Penelitian ini dilakukan pada PT Borwita Indah yang merupakan salah satu usaha yang mengawali bisnis usaha dibidang *e-commerce enabler* pada produk *consumer goods*.

Desain Penelitian

Penelitian ini menggunakan algoritma apriori yaitu mengambil data dengan aturan asosiatif (*association rule*) yang dilakukan melalui mekanisme perhitungan *support* dan *confidence* untuk menentukan hubungan asosiatif antara suatu kombinasi item dan juga untuk menemukan pola dengan frekuensi tinggi. Hasil dari algoritma apriori ini berupa data transaksi yang terbanyak terjual dari sebuah produk tersebut. Implementasi *frequent pattern growth* yang dapat digunakan untuk menentukan himpunan data yang paling sering

muncul (*frequent itemset*) dalam sebuah kumpulan data yang ada. Buat plot data masa lalu seperti, data pelatihan dan pengujian (Rohana et al., 2018).

Pada perhitungan itemset data *pattern* dibantu menggunakan *software* RapidMiner. Pada RapidMiner ini melakukan pengolahan itemset-itemset data untuk mengeliminasi produk yang tidak memenuhi dari kriteria nilai *support* dan nilai *confidence* Setelah *output* dari *software* RapidMiner yaitu Itemset frekuensi tinggi maka dilanjutkan ke proses berikutnya.

Validasi model peramalan dengan jaringan saraf tiruan yang merupakan metode peramalan yang memiliki tingkat *error* data yang cukup rendah dan cukup baik dalam proses generalisasi karena didukung oleh data *training* yang cukup dan proses pembelajaran yang menyesuaikan bobot sehingga, model ini mampu untuk meramalkan data *time series* untuk beberapa periode waktu ke depan.

Salah satu metode yang digunakan pada jaringan saraf tiruan dalam melakukan peramalan adalah algoritma *backpropagation*. Setelah itu dilakukan *tracking signal* untuk validasi model peramalan dengan hasil *outputs* dan *errors* dari *software* MatLab yang kemudian di denormalisasi untuk menghasilkan peramalan persediaan stok barang yang optimal (Mira Febrina, Faula Arina, 2013).

Algoritma Apriori

Algoritma apriori merupakan algoritma pengambilan data dengan aturan asosiatif (*association rule*) yang dilakukan melalui mekanisme perhitungan *support* dan *confidence* untuk menentukan hubungan asosiasi antara kombinasi item dan juga untuk menemukan pola dengan frekuensi tinggi. Suatu *association rule* akan dikatakan *interesting* jika memiliki nilai *support* yang lebih besar dari nilai minimum *support* dan juga nilai *confidence* yang lebih besar dari nilai minimum *confidence*. (Badrul et al., 2016).

Berikut merupakan langkah-langkah yang dilakukan pada metode algoritma apriori. Adapun dua tolok ukur dalam membentuk rules atau aturan dalam penerapan algoritma apriori adalah sebagai berikut:

1. *Support*

Support atau bisa juga disebut nilai penunjang adalah persentase dari laporan atau *record* yang didalamnya mengandung

kombinasi item. Persamaan (1) adalah rumus untuk mendapatkan nilai *support*.

$$Support(A) = \frac{\text{Jumlah Transaksi Mengandung A}}{\text{Total Transaksi}} \quad \text{Pers. 1}$$

Persamaan (2) adalah rumus untuk mendapatkan nilai *support* dari suatu kombinasi item.

$$Support(A, B) = \frac{\text{Jumlah Transaksi Mengandung A dan B}}{\text{Total Transaksi}} \quad \text{Pers. 2}$$

2. *Confidence*

Confidence atau biasa disebut nilai kepastian adalah kuatnya hubungan antar item dalam aturan asosiasi. Adapun rumus untuk mendapatkan nilai *confidence* ialah:

$$Confidence(A, B) = \frac{\text{Jumlah Transaksi Mengandung A dan B}}{\text{Total Transaksi Mengandung A}} \quad \text{Pers. 3}$$

atau,

$$Confidence(A \Rightarrow B) = \frac{Support(A, B)}{Support(A)} \quad \text{Pers. 4}$$

Sedangkan rumus mendapatkan nilai persentase *confidence* ialah:

$$Confidence(A \Rightarrow B) = \frac{Support(A, B)}{Support(A)} \times 100\% \quad \text{Pers. 5}$$

Jaringan Saraf Tiruan

Jaringan saraf tiruan merupakan metode peramalan yang memiliki tingkat *error* data yang cukup rendah dan cukup baik dalam proses generalisasi karena didukung oleh data *training* yang cukup dan proses pembelajaran yang menyesuaikan bobot sehingga model ini mampu untuk meramalkan data *time series* untuk beberapa periode waktu ke depan. Ciri khas *backpropagation* melibatkan tiga lapisan. (layer) utama: (1) lapisan masukan (input layer) berfungsi sebagai penghubung jaringan ke dunia luar (sumber data), (2) lapisan tersembunyi (*hidden layer*) di mana jaringan dapat memiliki lebih dari satu hidden layer atau bahkan bisa juga tidak memilikinya sama sekali; dan lapisan luaran (*output layer*) di mana hasil dari masukan yang diberikan oleh input layer.

Penyelesaian algoritma *backpropagation* menurut (Windarto, Agus Perdana, dkk. 2020) ada beberapa langkah sebagai berikut:

1. Membuat pola data masukan dan target
Jumlah data dalam satu periode dipakai sebagai jumlah masukan dalam *backpropagation*

2. Normalisasi data

Normalisasi data menggunakan fungsi aktivasi *sigmoid biner*, sehingga data akan dinormalisasi ke dalam *range* [0,1]. Untuk mengirimkan isyarat ini ke semua unit pada keluaran data normalisasi dengan rumus:

$$X_n = \frac{0,8(X_0 - X_{min})}{X_{max} - X_{min}} + 0,1 \quad \text{Pers. 6}$$

Dengan:

X_n = nilai data normal

X_0 = nilai data aktual

X_{min} = nilai minimum data aktual keseluruhan

3. Pembagian Data

Data dibagi menjadi data latih dan data uji dilakukan secara *trial* dan *error*.

4. Model Ramalan Permintaan Produk menggunakan JST

5. Denormalisasi Data

Denormalisasi data dilakukan agar data telah diperoleh dapat kembali kedalam satuan awal permintaan. Medenormalisasi data kembali menggunakan rumus:

$$y = \frac{(X_0 - 0,1)(X_{max} - X_{min})}{0,8} + X_{min}$$

Pers. 7

Dengan:

y = nilai data normal

X_0 = nilai data aktual

X_{min} = nilai minimum data aktual keseluruhan

X_{max} = nilai minimum data aktual keseluruhan

Safety Stock

Persediaan pengaman atau sering pula disebut *safety stock* adalah persediaan yang dilakukan untuk mengantisipasi unsur ketidakpastiaan permintaan dan penyediaan. Berikut adalah rumus dari *safety stock*:

$$\text{safety stock} = (\text{Pemakaian Maksimum} - T) \times C$$

Pers. 8

Keterangan:

T = Pemakaian barang rata-rata per periode (pcs)

C = *Lead time*

Hasil dan Analisis

Hasil Penelitian dari Algoritma Apriori

1. Nilai support

Menghitung nilai *support* pada algoritma apriori dapat dilakukan dengan melakukan 3

kali iterasi seperti dengan menggunakan 1 *itemset*, 2 *itemset*, dan 3 *itemset* dengan menentukan nilai *minimum support*-nya. Nilai *minimum support* yang ditetapkan pada penelitian ini adalah sebesar 30%.

a) 1 itemset

Rumus yang digunakan untuk perhitungan nilai *support* pada 1 *itemset* adalah Pers. 1:

$$\text{Support (A)} = \frac{\text{Jumlah Transaksi Mengandung A}}{\text{Total Transaksi}} \times 100\%$$

Berikut hasil yang didapatkan untuk nilai *support* pada 1 *itemset* dengan menggunakan *Microsoft Excel*:

$$\begin{aligned} S(\text{Pantene}) &= \frac{\sum \text{Transaksi Mengandung Pantene}}{\sum 12} \times 100\% \\ &= \frac{11}{12} \times 100\% = 91,6666667\% \end{aligned}$$

Berdasarkan hasil yang telah didapatkan pada Tabel 2 diketahui bahwa item atau produk Rejoice dan Olay tidak memenuhi syarat nilai *minimum support* yang telah ditetapkan sebelumnya yaitu sebesar 30%.

Tabel 2. Perhitungan nilai *support* dengan 1 *itemset*

No.	Item	Jumlah Transaksi	Support (%)
1	Pantene	11	91,6666667
2	Head&Shoulders	11	91,6666667
3	Rejoice	3	25
4	Vicks	4	33,3333333
5	Downy	4	33,3333333
6	Olay	3	25

b) 2 itemset

Rumus yang digunakan untuk perhitungan nilai *support* pada 2 *itemset* adalah Pers 2:

$$\begin{aligned} \text{Support (A, B)} &= \frac{\text{Jumlah Transaksi Mengandung A dan B}}{\text{Total Transaksi}} \\ &\times 100\% \end{aligned}$$

Berikut merupakan hasil yang di dapatkan untuk nilai *support* pada 2 *itemset* dengan menggunakan *Microsoft Excel*:

$$\begin{aligned} S(\text{Pantene, Head\&Shoulders}) &= \frac{\sum \text{Transaksi Mengandung Pantene dan H\&S}}{\sum 12} \\ &\times 100\% \end{aligned}$$

$$= \frac{10}{12} \times 100\% = 83,3333333\%$$

Berdasarkan hasil yang telah didapatkan pada Tabel 3 diketahui bahwa item atau

produk Pantene-Head&Shoulders dan Head&Shoulders-Vicks yang memenuhi syarat nilai minimum support yang telah ditetapkan sebelumnya yaitu sebesar 30%.

Tabel 3. Hasil perhitungan nilai *support* dengan 2 *itemset* yang memenuhi syarat

No	Item	Jumlah Transaksi	Support (%)
1	Pantene-Head&Shoulders	10	83,3333333
2	Head&Shoulders-Vicks	4	33,3333333

c) 3 *itemset*

Rumus yang di gunakan untuk perhitungan nilai *support* pada 3 *itemset* adalah sebagai berikut:

$$\text{Support (A, B, dan C)} = \frac{\text{Jumlah Transaksi Mengandung A, B, dan C}}{\text{Total Transaksi}} \times 100\%$$

Berikut merupakan hasil yang didapatkan untuk nilai *support* pada 3 *itemset* dengan menggunakan *Microsoft Excel*:

$$S(\text{Pantene, Head\&Shoulders, Vicks}) = \frac{\sum \text{Transaksi Mengandung Pantene, H\&S dan Vicks}}{\sum 12} \times 100\% = \frac{1}{12} \times 100\% = 8,3333333\%$$

Berdasarkan hasil yang telah didapatkan pada Tabel 4 diketahui bahwa semua *item* atau produk tidak ada yang memenuhi syarat nilai *minimum support* yang telah ditetapkan sebelumnya yaitu sebesar 30%.

Tabel 4. Hasil perhitungan nilai *support* dengan 3 *itemset* yang tidak memenuhi syarat

No	Item	Jumlah Transaksi	Support (%)
1	Pantene-Head&Shoulders-Vicks	1	8,33333333
2	Pantene-Head&Shoulders-Downy	1	8,33333333
3	Pantene-Vicks-Downy	1	8,33333333
4	Head&Shoulders-Vicks-Downy	1	8,33333333

2. Nilai Confidence

Nilai *minimum confidence* yang ditetapkan pada penelitian ini adalah sebesar 60% Rumus yang digunakan untuk perhitungan nilai *confidence* pada aturan asosiasi adalah Pers. 3:

Confidence

$$= \frac{\text{Jumlah Transaksi Mengandung A dan B}}{\text{Jumlah Transaksi Mengandung A}}$$

Maka berdasarkan Pers. 3:

$$\text{Confidence}_{\text{Pan dan H\&S}} = \frac{10}{11} \times 100\%$$

$$\text{Confidence}_{\text{Pan dan H\&S}} = 0,9090 \times 100\%$$

$$\text{Confidence}_{\text{Pan dan H\&S}} = 90,90\%$$

Berdasarkan hasil yang telah didapatkan pada Tabel 5 dan 6 diketahui bahwa terdapat beberapa aturan yang tidak memenuhi syarat nilai *support* yang telah ditetapkan sebelumnya yaitu sebesar 30%, dan nilai *confidence* 60% sehingga perlu dihilangkan atau dieleminasi, pada produk Rejoice dan Olay pada nilai *support* dan aturan jika membeli Head&Shoulders maka akan membeli Vicks yang hanya memiliki nilai *confidence* sebesar 36,36%.

Tabel 5. Hasil eliminasi nilai *support*

No	Item	Jumlah Transaksi	Support (%)
1	Pantene	11	91,6666667
2	Head&Shoulders	11	91,6666667
3	Rejoice	3	25
4	Vicks	4	33,3333333
5	Downy	4	33,3333333
6	Olay	3	25

Tabel 6. Hasil nilai *confidence*

No	Aturan	Confidence
1	Jika membeli Pantene, maka akan membeli Head&Shoulders	10/11 90,90%
2	Jika membeli Head&Shoulders, maka akan membeli Pantene	10/11 90,90%
3	Jika membeli Head&Shoulders, maka akan membeli Vicks	4/11 36,36%
4	Jika membeli Vicks, maka akan membeli Head&Shoulders	4/4 100%

3. Pengaplikasian *software* RapidMiner

Setelah dilakukan perhitungan langkah selanjutnya adalah melakukan *pattern data* dari data transaksi menggunakan *software* RapidMiner.

Berdasarkan Gambar 1 dan Gambar 2 hasil yang telah didapatkan melalui pengolahan data dengan menggunakan *software* RapidMiner di atas diketahui bahwa:

- a) Produk Head&Shoulders akan terbeli bersama dengan produk Pantene dengan tingkat kepercayaan sebesar 0,909 atau sebesar 90,9% yang diketahui berdasarkan nilai *confidence*-nya dan didukung oleh 0,833 atau sebesar 80,33% dari data keseluruhan yang ada.
- b) Produk Pantene akan terbeli bersama dengan produk Head&Shoulders dengan tingkat kepercayaan sebesar 0,909 atau sebesar 90,9% yang diketahui berdasarkan nilai *confidence*-nya dan didukung oleh 0,833 atau sebesar 80,33% dari data keseluruhan yang ada.
- c) Produk Vicks akan terbeli bersama dengan produk Head&Shoulders dengan tingkat kepercayaan sebesar 1 atau sebesar 100% yang diketahui berdasarkan nilai *confidence*-nya dan didukung oleh 0,333 atau sebesar 30,33% dari data keseluruhan yang ada.

No.	Premises	Conclusion	Support	Confidence
1	Head & Shoulders	Pantene	0.833	0.909
2	Pantene	Head & Shoulders	0.833	0.909
3	Vicks	Head & Shoulders	0.333	1

Gambar 1. Hasil pengolahan menggunakan RapidMiner dalam bentuk tabel

Association Rules

Association Rules

```
[Head & Shoulders] --> [Pantene] (confidence: 0.909)
[Pantene] --> [Head & Shoulders] (confidence: 0.909)
[Vicks] --> [Head & Shoulders] (confidence: 1.000)
```

Gambar 2. Hasil pengolahan menggunakan RapidMiner dalam bentuk deskripsi

Hasil Penelitian dari Jaringan Syaraf Tiruan

Pada penentuan arsitektur jaringan terbaik, data dibagi menjadi dua yaitu data pelatihan dan pengujian. Data pelatihan sebanyak 8 dan pengujian 4. Komposisi pembagian data ditekankan agar jaringan mendapat data pelatihan yang cukup dan dapat mengujikannya pada data uji.

1. Produk Pantene

- a. Membuat pola data masukan dan target

Jumlah data dalam satu periode dipakai sebagai jumlah masukan dalam *backpropagation*. Lalu target diambil dari data bulan pertama setelah periode berakhir.

Penelitian ini, masing-masing pola produk Pantene yang dipakai menggunakan data input selama 12 periode dan data target adalah data permintaan pada periode selanjutnya yaitu periode ke-13 seperti Tabel 7.

b. Normalisasi data

Normalisasi bertujuan agar jaringan tidak mengalami kegagalan ketika melakukan pembelajaran (pelatihan dan pengujian). Tabel 8 adalah data yang dinormalisasi dalam interval [0,1] karena terkait dengan fungsi aktivasi sigmoid biner. Berikut adalah perhitungan normalisasi terhadap data permintaan produk Pantene dengan Pers. 6:

$$X_n = 0,8 \times \frac{(X_0 - X_{\min})}{X_{\max} - X_{\min}} + 0,1$$

$$X_n = 0,8 \times \frac{(202 - 54)}{(2731 - 54)} + 0,1$$

$$X_n = 0,144229$$

c. Pelatihan Data

Pelatihan data merupakan validasi model jaringan. Berdasarkan Tabel 8 data dibagi menjadi data latih dan data uji dilakukan secara *trial* dan *error*. Pelatihan data dilakukan beberapa kali untuk mendapatkan jaringan terbaik dengan menentukan jumlah neuron.

Pada Tabel 9 dilakukan dengan perubahan jumlah neuron dan dapat dilihat dengan jumlah neuron 3 dan hidden layer 3 didapatkan *error* terkecil (MSE) yaitu 0,0034. Peramalan terhadap permintaan produk Pantene PT Borwita Indah menggunakan model jaringan syaraf tiruan dengan arsitektur jaringan algoritma *backpropagation* yang bersifat *supervised learning* dimana fungsi pelatihan jaringan yang digunakan adalah *TrainGD* dan fungsi pelatihan untuk bobot adalah *LearnGDM*.

Berdasarkan percobaan mencari arsitektur terbaik didapatkan yaitu menggunakan 8 variabel lapisan masukan, 1 lapisan tersembunyi dengan 3 *neuron* dan 1 lapisan keluaran. Beberapa parameter

Tabel 7. Pola data masukan dan target produk pantene

Periode	Input												
1	202	451	260	366	157	54	462	113	157	251	485	1557	
2	451	260	366	157	54	462	113	157	251	485	1557	1048	
3	260	366	157	54	462	113	157	251	485	1557	1048	1283	
4	366	157	54	462	113	157	251	485	1557	1048	1283	2731	
5	157	54	462	113	157	251	485	1557	1048	1283	2731	462	
6	54	462	113	157	251	485	1557	1048	1283	2731	462	113	
7	462	113	157	251	485	1557	1048	1283	2731	462	113	157	
8	113	157	251	485	1557	1048	1283	2731	462	113	157	468	
9	157	251	485	1557	1048	1283	2731	462	113	157	468	213	
10	251	485	1557	1048	1283	2731	462	113	157	468	213	364	
11	485	1557	1048	1283	2731	462	113	157	468	213	364	273	
12	1557	1048	1283	2731	462	113	157	468	213	364	273	485	
Target	1048	1283	2731	462	113	157	468	213	364	273	485	1553	

Tabel 8. Data normalisasi target dan input produk pantene

Periode	Input												
1	0,144	0,219	0,162	0,193	0,131	0,1	0,222	0,118	0,131	0,159	0,229	0,549	
2	0,219	0,162	0,193	0,131	0,1	0,222	0,118	0,131	0,159	0,229	0,549	0,397	
3	0,162	0,193	0,131	0,1	0,222	0,118	0,131	0,159	0,229	0,549	0,397	0,467	
4	0,193	0,131	0,1	0,222	0,118	0,131	0,159	0,229	0,549	0,397	0,467	0,9	
5	0,131	0,1	0,222	0,118	0,131	0,159	0,229	0,549	0,397	0,467	0,9	0,222	
6	0,1	0,222	0,118	0,131	0,159	0,229	0,549	0,397	0,467	0,9	0,222	0,118	
7	0,222	0,118	0,131	0,159	0,229	0,549	0,397	0,467	0,9	0,222	0,118	0,131	
8	0,118	0,131	0,159	0,229	0,549	0,397	0,467	0,9	0,222	0,118	0,131	0,224	
9	0,131	0,159	0,229	0,549	0,397	0,467	0,9	0,222	0,118	0,131	0,224	0,148	
10	0,159	0,229	0,549	0,397	0,467	0,9	0,222	0,118	0,131	0,224	0,148	0,193	
11	0,229	0,549	0,397	0,467	0,9	0,222	0,118	0,131	0,224	0,148	0,193	0,165	
12	0,549	0,397	0,467	0,9	0,222	0,118	0,131	0,224	0,148	0,193	0,165	0,229	
Target	0,397	0,467	0,9	0,222	0,118	0,131	0,224	0,148	0,193	0,165	0,229	0,548	

yang digunakan yaitu *goal 0*, *learning rate 0.07*, *epoch 2500* dan fungsi aktivitas yang digunakan adalah fungsi *sigmoid biner (logsig)*. Hasil dari arsitektur terpilih mendapatkan nilai MSE pelatihan sebesar 0.00341 dan nilai regression 0,96492 maka baik untuk ditetapkan dalam peramalan permintaan produk Pantene PT Borwita Indah.

Output yang diperoleh dari training beserta nilai *error* antar *output* dan targetnya dapat dilihat pada Tabel 10.

d. Denormalisasi Data

Proses denormalisasi data dilakukan agar data telah diperoleh dapat kembali kedalam satuan awal permintaan. Pers. 7 adalah perhitungan denormalisasi terhadap data hasil peramalan permintaan produk Pantene:

1) Denormalisasi Periode 1

$$y = \frac{(X_0 - 0,1)(X_{\max} - X_{\min})}{0,8} + X_{\min}$$

$$y = \frac{(0,4520 - 0,1)(2731 - 54)}{0,8} + 54$$

$$= 1231,88$$

2) Denormalisasi Periode 2

$$y = \frac{(X_0 - 0,1)(X_{\max} - X_{\min})}{0,8} + X_{\min}$$

$$y = \frac{(0,4744 - 0,1)(2731 - 54)}{0,8} + 54$$

$$= 1306,836$$

3) Denormalisasi Periode 3

$$y = \frac{(X_0 - 0,1)(X_{\max} - X_{\min})}{0,8} + X_{\min}$$

$$y = \frac{(0,7215 - 0,1)(2731 - 54)}{0,8} + 54$$

$$= 2133,694375$$

4) Dan seterusnya

Tabel 9. Pelatihan data dengan berbagai rancangan JST produk pantene

No	Nama	Input						Output					
		TF	ALF	NO Neurons	Epoch	Max_fail	Lr (Learning Rate)	Epoch	Time	MSE	Gradient	Validation Check	Regression
1	Network1	TrainGD	LearnGDM	2	100	100	0,01	100	00:00	0,0263	0,0205	43	0,27953
2	Network1	TrainGD	LearnGDM	2	150	100	0,02	100	00:00	0,0191	0,0315	100	0,34071
3	Network1	TrainGD	LearnGDM	2	300	300	0,03	300	00:00	0,0217	0,0106	204	0,45209
4	Network1	TrainGD	LearnGDM	2	500	500	0,04	500	00:00	0,0160	0,0128	500	0,5966
5	Network1	TrainGD	LearnGDM	2	700	700	0,05	700	00:00	0,0139	0,0087	688	0,66507
6	Network1	TrainGD	LearnGDM	2	1000	100	0,06	100	00:00	0,0104	0,0240	100	0,65013
7	Network1	TrainGD	LearnGDM	2	1500	100	0,07	100	00:00	0,0221	0,0180	100	0,69853
8	Network2	TrainGD	LearnGDM	3	1000	1000	0,01	1000	00:00	0,0193	0,0113	1000	0,52181
9	Network2	TrainGD	LearnGDM	3	1500	1000	0,02	1500	00:00	0,0166	0,0102	1000	0,61198
10	Network2	TrainGD	LearnGDM	3	1500	1500	0,03	1500	00:01	0,0155	0,0077	1500	0,61198
11	Network2	TrainGD	LearnGDM	3	2000	1500	0,04	1500	00:00	0,0011	0,0033	1500	0,67385
12	Network2	TrainGD	LearnGDM	3	2000	2000	0,05	2000	00:01	0,0005	0,0019	2000	0,70708
13	Network2	TrainGD	LearnGDM	3	2500	2000	0,06	2043	00:01	0,0082	0,0045	2000	0,84369
14	Network2	TrainGD	LearnGDM	3	2500	2500	0,07	2500	00:01	0,0003	0,0013	2498	0,98065
15	Network3	TrainGD	LearnGDM	6	1500	1000	0,01	1000	00:00	0,0168	0,0139	1000	0,54997
16	Network3	TrainGD	LearnGDM	6	1500	1500	0,02	1500	00:00	0,0066	0,0093	1500	0,78221
17	Network3	TrainGD	LearnGDM	6	2000	1500	0,03	1529	00:01	0,0069	0,0078	1500	0,78778
18	Network3	TrainGD	LearnGDM	6	2000	2000	0,04	2000	00:01	0,0060	0,0057	2000	0,78778
19	Network3	TrainGD	LearnGDM	6	2000	2500	0,05	2000	00:01	0,0039	0,0032	1894	0,81774
20	Network3	TrainGD	LearnGDM	6	2500	2500	0,06	2500	00:01	0,0030	0,0051	2233	0,91322
21	Network3	TrainGD	LearnGDM	6	3000	2500	0,07	2514	00:01	0,0001	0,0030	2500	0,92425

Tabel 10. Output JST produk pantene

Periode	Output	Error
1	0,4520	-0,0550
2	0,4744	-0,0071
3	0,7215	0,1785
4	0,2696	-0,0477
5	0,1918	-0,0742
6	0,1697	-0,0389
7	0,1647	0,0591
8	0,1414	0,0061
9	0,1351	0,0576
10	0,1868	-0,0214
11	0,2467	-0,0179
12	0,5384	0,0096

Pada Tabel 11 ditampilkan hasil peramalan permintaan produk pantene menggunakan JST dimana terdapat 12 periode untuk bulan Juni 2023 – Mei 2024, maka masing-masing periode menampilkan peramalan selama 1 bulan.

Tabel 11. Hasil peramalan permintaan produk pantene

Periode	Permintaan	Pembulatan
1	1231,88	1232
2	1306,836	1307
3	2133,694375	2134
4	621,524	622
5	361,18575	361
6	287,233625	287
7	270,502375	271
8	192,53475	193
9	171,453375	171
10	344,4545	344
11	544,894875	545
12	1520,996	1521

Hasil peramalan dengan metode jaringan syaraf tiruan backpropagation untuk 12 periode kedepan atau bulan Juni 2023 – Mei 2024 yaitu 1232, 1307, 2134, 622, 361, 287, 271, 193, 171, 344, 545, dan 1521 pcs.

e. *Safety Stock*

Nilai dari *lead time* (LT) adalah 7 hari kerja atau 1 minggu didapat dari bagian operational PT Borwita Indah. Hasil perhitungan diperoleh nilai rata-rata permintaan produk Pantene selama *lead time* sebesar 19 pcs dengan nilai permintaan tertinggi sebesar 91 pcs. Maka berdasarkan Pers. 8:

$$safety\ stock = (Pemakaian\ Maksimum - T) \times C$$

$$SS = (91 - 19) \times 7$$

$$SS = 504\ pcs/hari$$

Diperoleh nilai *safety stock* produk Pantene yang harus ada pada perusahaan sebanyak 504 pcs per harinya.

2. **Produk Head&Shoulders**

a. Membuat pola data masukan dan target
 Jumlah data dalam satu periode dipakai sebagai jumlah masukan dalam backpropagation. Lalu target diambil dari data bulan pertama setelah periode berakhir. Dalam penelitian ini, masing-masing pola produk Head&Shoulders yang dipakai menggunakan data input selama 12 periode dan data target adalah data permintaan pada periode selanjutnya yaitu periode ke-13 seperti Tabel 12.

b. Normalisasi data

Normalisasi bertujuan agar jaringan tidak mengalami kegagalan ketika melakukan pembelajaran (pelatihan dan pengujian). Tabel 13 adalah data yang dinormalisasi dalam interval [0,1] karena terkait dengan fungsi aktivasi sigmoid biner. Berikut adalah perhitungan normalisasi

terhadap data permintaan produk Head&Shoulders dengan Pers 6:

$$X_n = 0,8 \times \frac{(X_0 - X_{min})}{X_{max} - X_{min}} + 0,1$$

$$X_n = 0,8 \times \frac{(110 - 33)}{(360 - 33)} + 0,1$$

$$X_n = 0,288379$$

c. *Pelatihan Data*

Pelatihan data merupakan validasi model jaringan. Berdasarkan Tabel 13 data dibagi menjadi data latih dan data uji dilakukan secara *trial* dan *error*. *Pelatihan data* dilakukan beberapa kali untuk mendapatkan jaringan terbaik dengan menentukan jumlah neuron.

Pada Tabel 14 dilakukan dengan perubahan jumlah neuron dan dapat dilihat dengan jumlah neuron 3 dan hidden layer 3 didapatkan *error* terkecil (MSE) yaitu 0,0003. Peramalan terhadap permintaan produk Head&Shoulders PT Borwita Indah menggunakan model jaringan syaraf tiruan dengan arsitektur jaringan algoritma *backpropagation* yang bersifat *supervised learning* dimana fungsi pelatihan jaringan yang digunakan adalah *TrainGD* dan fungsi pelatihan untuk bobot adalah *LearnGDM*.

Berdasarkan percobaan mencari arsitektur terbaik didapatkan yaitu menggunakan 8 variabel lapisan masukan, 1 lapisan tersembunyi dengan 3 *neuron* dan 1 lapisan keluaran. Beberapa parameter yang digunakan yaitu *goal* 0, *learning rate* 0.07, *epoch* 2500 dan fungsi aktivitas yang digunakan adalah fungsi *sigmoid biner* (logsig). Hasil dari arsitektur terpilih

Tabel 12. Pola data masukan dan target produk Head&Shoulders

Periode	Input											
1	110	251	360	227	74	33	207	97	47	111	138	142
2	251	360	227	74	33	207	97	47	111	138	142	166
3	360	227	74	33	207	97	47	111	138	142	166	189
4	227	74	33	207	97	47	111	138	142	166	189	234
5	74	33	207	97	47	111	138	142	166	189	234	217
6	33	207	97	47	111	138	142	166	189	234	217	239
7	207	97	47	111	138	142	166	189	234	217	239	77
8	97	47	111	138	142	166	189	234	217	239	77	47
9	47	111	138	142	166	189	234	217	239	77	47	207
10	111	138	142	166	189	234	217	239	77	47	207	197
11	138	142	166	189	234	217	239	77	47	207	197	97
12	142	166	189	234	217	239	77	47	207	197	97	211
Target	166	189	234	217	239	77	47	207	197	97	211	131

Tabel 13. Data normalisasi target dan input produk Head&Shoulders

Periode	Input												
1	0,288	0,633	0,9	0,575	0,2	0,1	0,526	0,257	0,134	0,291	0,357	0,367	
2	0,633	0,9	0,575	0,2	0,1	0,526	0,257	0,134	0,291	0,357	0,367	0,425	
3	0,9	0,575	0,2	0,1	0,526	0,257	0,134	0,291	0,357	0,367	0,425	0,482	
4	0,575	0,2	0,1	0,526	0,257	0,134	0,291	0,357	0,367	0,425	0,482	0,592	
5	0,2	0,1	0,526	0,257	0,134	0,291	0,357	0,367	0,425	0,482	0,592	0,55	
6	0,1	0,526	0,257	0,134	0,291	0,357	0,367	0,425	0,482	0,592	0,55	0,604	
7	0,526	0,257	0,134	0,291	0,357	0,367	0,425	0,482	0,592	0,55	0,604	0,208	
8	0,257	0,134	0,291	0,357	0,367	0,425	0,482	0,592	0,55	0,604	0,208	0,134	
9	0,134	0,291	0,357	0,367	0,425	0,482	0,592	0,55	0,604	0,208	0,134	0,526	
10	0,291	0,357	0,367	0,425	0,482	0,592	0,55	0,604	0,208	0,134	0,526	0,501	
11	0,357	0,367	0,425	0,482	0,592	0,55	0,604	0,208	0,134	0,526	0,501	0,257	
12	0,367	0,425	0,482	0,592	0,55	0,604	0,208	0,134	0,526	0,501	0,257	0,535	
Target	0,425	0,482	0,592	0,55	0,604	0,208	0,134	0,526	0,501	0,257	0,535	0,34	

mendapatkan nilai MSE pelatihan sebesar 0.0003 dan nilai regression 0,98065 maka baik untuk ditetapkan dalam peramalan permintaan produk Head&Shoulders PT Borwita Indah.

Output yang diperoleh dari training beserta nilai *error* antar *output* dan target-nya dapat dilihat pada Tabel 15.

Tabel 14. Pelatihan data dengan berbagai rancangan JST produk Head&Shoulders

No	Nama	Input						Output					
		TF	ALF	NO Neurons	Epoch	Max_fail	Lr (Learning Rate)	Epoch	Time	MSE	Gradient	Validation Check	Regression
1	Network1	TrainGD	LearnGDM	2	100	100	0,01	100	00:00	0,0263	0,0205	43	0,27953
2	Network1	TrainGD	LearnGDM	2	150	100	0,02	100	00:00	0,0191	0,0315	100	0,34071
3	Network1	TrainGD	LearnGDM	2	300	300	0,03	300	00:00	0,0217	0,0106	204	0,45209
4	Network1	TrainGD	LearnGDM	2	500	500	0,04	500	00:00	0,0160	0,0128	500	0,5966
5	Network1	TrainGD	LearnGDM	2	700	700	0,05	700	00:00	0,0139	0,00872	688	0,66507
6	Network1	TrainGD	LearnGDM	2	1000	100	0,06	100	00:00	0,0104	0,0240	100	0,65013
7	Network1	TrainGD	LearnGDM	2	1500	100	0,07	100	00:00	0,0221	0,0180	100	0,69853
8	Network2	TrainGD	LearnGDM	3	1000	1000	0,01	1000	00:00	0,0193	0,0113	1000	0,52181
9	Network2	TrainGD	LearnGDM	3	1500	1000	0,02	1500	00:00	0,0166	0,0102	1000	0,61198
10	Network2	TrainGD	LearnGDM	3	1500	1500	0,03	1500	00:01	0,0155	0,00774	1500	0,61198
11	Network2	TrainGD	LearnGDM	3	2000	1500	0,04	1500	00:00	0,0011	0,00329	1500	0,67385
12	Network2	TrainGD	LearnGDM	3	2000	2000	0,05	2000	00:01	0,0005	0,0019	2000	0,70708
13	Network2	TrainGD	LearnGDM	3	2500	2000	0,06	2043	00:01	0,0082	0,00447	2000	0,84369
14	Network2	TrainGD	LearnGDM	3	2500	2500	0,07	2500	00:01	0,0003	0,00126	2498	0,98065
15	Network3	TrainGD	LearnGDM	6	1500	1000	0,01	1000	00:00	0,0168	0,0139	1000	0,54997
16	Network3	TrainGD	LearnGDM	6	1500	1500	0,02	1500	00:00	0,0066	0,0093	1500	0,78221
17	Network3	TrainGD	LearnGDM	6	2000	1500	0,03	1529	00:01	0,0069	0,0078	1500	0,78778
18	Network3	TrainGD	LearnGDM	6	2000	2000	0,04	2000	00:01	0,0060	0,0057	2000	0,78778
19	Network3	TrainGD	LearnGDM	6	2000	2500	0,05	2000	00:01	0,0039	0,0032	1894	0,81774
20	Network3	TrainGD	LearnGDM	6	2500	2500	0,06	2500	00:01	0,0030	0,0051	2233	0,91322
21	Network3	TrainGD	LearnGDM	6	3000	2500	0,07	2514	00:01	0,0001	0,0031	2500	0,92425

Tabel 15. Output JST produk Head&Shoulders

Periode	Output	Error
1	0,42573	-0,00034744
2	0,48311	-0,0014559
3	0,56835	0,023392
4	0,54463	0,0055197
5	0,60305	0,00092389
6	0,20622	0,0014207
7	0,24522	-0,11097
8	0,52873	-0,0030417
9	0,47277	0,028457
10	0,25394	0,0026313
11	0,52724	0,0082317
12	0,33983	-6,9609e-05

d. Denormalisasi Data

Proses denormalisasi data dilakukan agar data telah diperoleh dapat kembali kedalam satuan awal permintaan. Pers. 7 adalah perhitungan denormalisasi terhadap data hasil peramalan permintaan produk Head&Shoulders:

1) Denormalisasi Periode 1

$$y = \frac{(X_0 - 0,1)(X_{\max} - X_{\min})}{0,8} + X_{\min}$$

$$y = \frac{(0,42573 - 0,1)(360 - 33)}{0,8} + 33$$

$$= 166,142138$$

2) Denormalisasi Periode 2

$$y = \frac{(X_0 - 0,1)(X_{\max} - X_{\min})}{0,8} + X_{\min}$$

$$y = \frac{(0,48311 - 0,1)(360 - 33)}{0,8} + 33$$

$$= 189,596213$$

3) Denormalisasi Periode 3

$$y = \frac{(X_0 - 0,1)(X_{\max} - X_{\min})}{0,8} + X_{\min}$$

$$y = \frac{(0,56835 - 0,1)(360 - 33)}{0,8} + 33$$

$$= 224,438063$$

4) Dan seterusnya

Pada Tabel 16. ditampilkan hasil peramalan permintaan produk Head&Shoulders menggunakan JST dimana terdapat 12 periode untuk bulan Juni 2023 – Mei 2024, maka masing-masing periode menampilkan peramalan selama 1 bulan.

Hasil peramalan dengan metode Jaringan Syaraf Tiruan *backpropagation* untuk 12 periode kedepan atau bulan Juni 2023 – Mei 2024 yaitu 166, 190, 224, 215, 239, 76, 92, 208, 185, 96, 208, dan 131 pcs.

Tabel 16. Hasil peramalan permintaan produk Head&Shoulders

Periode	Permintaan	Pembulatan
1	166,1421375	166
2	189,5962125	190
3	224,4380625	224
4	214,7425125	215
5	238,6216875	239
6	76,417425	76
7	92,358675	92
8	208,2433875	208
9	185,3697375	185
10	95,922975	96
11	207,63435	208
12	131,0305125	131

e. Safety Stock

Nilai dari *lead time* (LT) adalah 7 hari kerja atau 1 minggu didapat dari bagian operational PT Borwita Indah. Hasil perhitungan diperoleh nilai rata-rata permintaan produk Head&Shoulders selama *lead time* sebesar 5 pcs dengan nilai permintaan tertinggi sebesar 12 pcs. Maka berdasarkan Pers. 8:

$$safety\ stock = (\text{Pemakaian Maksimum} - T) \times C$$

$$SS = (12 - 5) \times 7$$

$$SS = 49\ pcs/hari$$

Diperoleh nilai *safety stock* produk Head&Shoulders yang harus ada pada perusahaan sebanyak 49 pcs per harinya.

3. Produk Vicks

a. Membuat pola data masukan dan target

Jumlah data dalam satu periode dipakai sebagai jumlah masukan dalam *backpropagation*. Lalu target diambil dari data bulan pertama setelah periode berakhir. Dalam penelitian ini, masing-masing pola produk Vicks yang dipakai menggunakan data input selama 12 periode dan data target adalah data permintaan pada periode selanjutnya yaitu periode ke-13 seperti Tabel 17.

b. Normalisasi data

Normalisasi bertujuan agar jaringan tidak mengalami kegagalan ketika melakukan pembelajaran (pelatihan dan pengujian). Tabel 18 adalah data yang dinormalisasi dalam interval [0,1] karena terkait dengan fungsi aktivasi sigmoid biner. Berikut adalah perhitungan normalisasi

terhadap data permintaan produk Vicks dengan Pers. 6:

$$X_n = 0,8 \times \frac{(X_0 - X_{\min})}{X_{\max} - X_{\min}} + 0,1$$

$$X_n = 0,8 \times \frac{(44 - 23)}{(220 - 23)} + 0,1$$

$$X_n = 0,185279$$

c. Pelatihan Data

Pelatihan data merupakan validasi model jaringan. Berdasarkan Tabel 18 data dibagi menjadi data latih dan data uji dilakukan secara *trial* dan *error*. Pelatihan data dilakukan beberapa kali untuk mendapatkan jaringan terbaik dengan menentukan jumlah neuron.

Pada Tabel 19. dilakukan dengan perubahan jumlah neuron dan dapat dilihat dengan jumlah neuron 3 dan *hidden layer* 3 didapatkan *error* terkecil (MSE) yaitu 0,0023. Peramalan terhadap permintaan produk Head&Shoulders PT Borwita Indah menggunakan model jaringan syaraf tiruan

dengan arsitektur jaringan algoritma *backpropagation* yang bersifat *supervised learning* dimana fungsi pelatihan jaringan yang digunakan adalah *TrainGD* dan fungsi pelatihan untuk bobot adalah *LearnGDM*.

Berdasarkan percobaan mencari arsitektur terbaik didapatkan yaitu menggunakan 8 variabel lapisan masukan, 1 lapisan tersembunyi dengan 3 *neuron* dan 1 lapisan keluaran. Beberapa parameter yang digunakan yaitu *goal* 0, *learning rate* 0.07, *epoch* 2500 dan fungsi aktivitas yang digunakan adalah fungsi *sigmoid biner* (*logsig*). Hasil dari arsitektur terpilih mendapatkan nilai MSE pelatihan sebesar 0.00238 dan nilai regression 0,96267 maka baik untuk ditetapkan dalam peramalan permintaan produk Vicks PT Borwita Indah.

Output yang diperoleh dari training beserta nilai *error* antar *output* dan targetnya dapat dilihat pada Tabel 20.

Tabel 17. Pola data masukan dan target produk Vicks

Periode	Input											
1	44	27	89	101	124	89	77	46	77	43	73	53
2	27	89	101	124	89	77	46	77	43	73	53	34
3	89	101	124	89	77	46	77	43	73	53	34	23
4	101	124	89	77	46	77	43	73	53	34	23	79
5	124	89	77	46	77	43	73	53	34	23	79	104
6	89	77	46	77	43	73	53	34	23	79	104	114
7	77	46	77	43	73	53	34	23	79	104	114	220
8	46	77	43	73	53	34	23	79	104	114	220	75
9	77	43	73	53	34	23	79	104	114	220	75	24
10	43	73	53	34	23	79	104	114	220	75	24	79
11	73	53	34	23	79	104	114	220	75	24	79	48
12	53	34	23	79	104	114	220	75	24	79	48	73
Target	34	23	79	104	114	220	75	24	79	48	73	33

Tabel 18. Data normalisasi target dan input produk Vicks

Periode	Input											
1	0,185	0,116	0,368	0,417	0,51	0,368	0,319	0,193	0,319	0,181	0,303	0,222
2	0,116	0,368	0,417	0,51	0,368	0,319	0,193	0,319	0,181	0,303	0,222	0,145
3	0,368	0,417	0,51	0,368	0,319	0,193	0,319	0,181	0,303	0,222	0,145	0,1
4	0,417	0,51	0,368	0,319	0,193	0,319	0,181	0,303	0,222	0,145	0,1	0,327
5	0,51	0,368	0,319	0,193	0,319	0,181	0,303	0,222	0,145	0,1	0,327	0,429
6	0,368	0,319	0,193	0,319	0,181	0,303	0,222	0,145	0,1	0,327	0,429	0,47
7	0,319	0,193	0,319	0,181	0,303	0,222	0,145	0,1	0,327	0,429	0,47	0,9
8	0,193	0,319	0,181	0,303	0,222	0,145	0,1	0,327	0,429	0,47	0,9	0,311
9	0,319	0,181	0,303	0,222	0,145	0,1	0,327	0,429	0,47	0,9	0,311	0,104
10	0,181	0,303	0,222	0,145	0,1	0,327	0,429	0,47	0,9	0,311	0,104	0,327
11	0,303	0,222	0,145	0,1	0,327	0,429	0,47	0,9	0,311	0,104	0,327	0,202
12	0,222	0,145	0,1	0,327	0,429	0,47	0,9	0,311	0,104	0,327	0,202	0,303
Target	0,145	0,1	0,327	0,429	0,47	0,9	0,311	0,104	0,327	0,202	0,303	0,141

Tabel 19. Pelatihan data dengan berbagai rancangan JST produk Vicks

No	Nama	Input						Output					
		TF	ALF	NO Neurons	Epoch	Max_fail	Lr (Learning Rate)	Epoch	Time	MSE	Gradient	Validation Check	Regression
1	Network1	TrainGD	LearnGDM	2	100	100	0,01	100	00:00	0,0144	0,0415	100	0,78823
2	Network1	TrainGD	LearnGDM	2	150	100	0,02	100	00:00	0,0082	0,0295	100	0,78823
3	Network1	TrainGD	LearnGDM	2	300	300	0,03	300	00:00	0,0148	0,0148	300	0,79821
4	Network1	TrainGD	LearnGDM	2	500	500	0,04	500	00:00	0,0087	0,0062	345	0,82867
5	Network1	TrainGD	LearnGDM	2	700	700	0,05	700	00:00	0,0623	0,0056	700	0,89724
6	Network1	TrainGD	LearnGDM	2	1000	100	0,06	101	00:00	0,0051	0,0036	100	0,89752
7	Network1	TrainGD	LearnGDM	2	1500	100	0,07	100	00:00	0,0096	0,0096	100	0,91858
8	Network2	TrainGD	LearnGDM	3	1000	1000	0,01	1000	00:00	0,0098	0,0149	1000	0,83246
9	Network2	TrainGD	LearnGDM	3	1500	1000	0,02	1000	00:00	0,0084	0,0107	1000	0,83246
10	Network2	TrainGD	LearnGDM	3	1500	1500	0,03	1500	00:01	0,0062	0,0054	955	0,89221
11	Network2	TrainGD	LearnGDM	3	2000	1500	0,04	2000	00:01	0,0087	0,0049	177	0,91388
12	Network2	TrainGD	LearnGDM	3	2000	2000	0,05	2000	00:01	0,0092	0,0044	2000	0,92101
13	Network2	TrainGD	LearnGDM	3	2500	2000	0,06	2000	00:01	0,0061	0,0051	2000	0,92529
14	Network2	TrainGD	LearnGDM	3	2500	2500	0,07	2500	00:01	0,0023	0,0021	2500	0,96267
15	Network3	TrainGD	LearnGDM	6	1500	1000	0,01	1500	00:01	0,0142	0,0126	1500	0,83705
16	Network3	TrainGD	LearnGDM	6	1500	1500	0,02	1500	00:00	0,0029	0,0049	1500	0,84135
17	Network3	TrainGD	LearnGDM	6	2000	1500	0,03	1500	00:01	0,0070	0,0031	1500	0,87631
18	Network3	TrainGD	LearnGDM	6	2000	2000	0,04	2000	00:01	0,0409	0,0049	1135	0,92039
19	Network3	TrainGD	LearnGDM	6	2000	2500	0,05	2202	00:01	0,0071	0,0082	2000	0,93711
20	Network3	TrainGD	LearnGDM	6	2500	2500	0,06	2500	00:01	0,0067	0,0012	2500	0,9537
21	Network3	TrainGD	LearnGDM	6	3000	2500	0,07	2500	00:01	0,0066	0,0009	2500	0,95687

Tabel 20. Output JST produk Vicks

Periode	Output	Error
1	0,19484	-0,050173
2	0,15091	-0,050908
3	0,18825	0,13917
4	0,44288	-0,013945
5	0,49847	-0,028931
6	0,85247	0,047534
7	0,3305	-0,019332
8	0,17578	-0,071716
9	0,30103	0,026377
10	0,21263	-0,011104
11	0,23342	0,069629
12	0,18871	-0,048103

d. Denormalisasi Data

Proses denormalisasi data dilakukan agar data telah diperoleh dapat kembali kedalam satuan awal permintaan. Pers. 7 adalah perhitungan denormalisasi terhadap data hasil peramalan permintaan produk Vicks:

1) Denormalisasi Periode 1

$$y = \frac{(X_0 - 0,1)(X_{\max} - X_{\min})}{0,8} + X_{\min}$$

$$y = \frac{(0,19484 - 0,1)(220 - 23)}{0,8} + 23$$

$$= 46,35435$$

2) Denormalisasi Periode 2

$$y = \frac{(X_0 - 0,1)(X_{\max} - X_{\min})}{0,8} + X_{\min}$$

$$y = \frac{(0,15091 - 0,1)(220 - 23)}{0,8} + 23$$

$$= 35,53658$$

3) Denormalisasi Periode 3

$$y = \frac{(X_0 - 0,1)(X_{\max} - X_{\min})}{0,8} + X_{\min}$$

$$y = \frac{(0,18825 - 0,1)(220 - 23)}{0,8} + 23$$

$$= 44,73156$$

4) Dan seterusnya

Pada Tabel 21 ditampilkan hasil peramalan permintaan produk Vicks menggunakan JST dimana terdapat 12 periode untuk bulan Juni 2023 – Mei 2024, maka masing-masing periode menampilkan peramalan selama 1 bulan.

Tabel 21. Hasil peramalan permintaan produk Vicks

Periode	Permintaan	Pembulatan
1	46,35435	46
2	35,5365875	36
3	44,7315625	45
4	107,4342	107
5	121,1232375	121
6	208,2957375	208
7	79,760625	80
8	41,660825	42
9	72,50363751	73
10	50,7351375	51
11	55,854675	56
12	44,8448375	45

Hasil peramalan dengan metode Jaringan Syaraf Tiruan *backpropagation* untuk 12 periode kedepan atau bulan Juni 2023 – Mei 2024 yaitu 46, 36, 45, 107, 121, 208, 80, 42, 73, 51, 56, dan 45 pcs.

e. *Safety Stock*

Nilai dari *lead time* (LT) adalah 7 hari kerja atau 1 minggu didapat dari bagian operational PT Borwita Indah. Hasil perhitungan diperoleh nilai rata-rata permintaan produk Vicks selama *lead time* sebesar 2 pcs dengan nilai permintaan tertinggi sebesar 7 pcs. Maka berdasarkan Pers. 8:

$$safety\ stock = (Pemakaian\ Maksimum - T) \times C$$

$$SS = (7 - 2) \times 7$$

$$SS = 35\ pcs/hari$$

Diperoleh nilai *safety stock* produk Vicks yang harus ada pada perusahaan sebanyak 35 pcs per harinya.

Kesimpulan

Penelitian ini dilakukan untuk menentukan Itemset data *pattern* yang menghasilkan tingkat kepercayaan pada produk Head&Shoulders dengan produk Pantene sebesar 90,9%, serta tingkat kepercayaan Pantene dengan produk Head&Shoulders sebesar 90,9%. Sementara itu, tingkat kepercayaan untuk produk Vicks dengan Head&Shoulders mencapai 100%

Penelitian ini menggunakan metode Jaringan Syaraf Tiruan untuk menentukan hasil peramalan untuk 12 periode kedepan atau bulan Juni 2023 – Mei 2024 yaitu 1232, 1307, 2134, 622, 361, 287, 271, 193, 171, 344, 545, dan 1521 pcs untuk produk Pantene. Lalu untuk produk Head&Shoulders 166, 190, 224, 215, 239, 76, 92, 208, 185, 96, 208, dan 131 pcs.

Serta untuk produk Vicks 46, 36, 45, 107, 121, 208, 80, 42, 73, 51, 56, dan 45 pcs. Perusahaan dapat menggunakan hasil peramalan untuk menentukan persediaan stok pada gudang.

Berdasarkan penelitian, jumlah *safety stock* yang harus ada pada perusahaan adalah 504 pcs produk Pantene per hari, produk Head&Shoulders 49 pcs per harinya, produk Vicks 35 pcs. Ketersediaan sudah optimal ketika bisa meminimalisir dari hasil *safety stock* serta dari hasil peramalan yang sudah di dapatkan. Berdasarkan hasil di dapat di harapkan perusahaan dapat melakukan perencanaan persediaan yang efisien dan optimal.

Rekomendasi penelitian selanjutnya adalah membuat perancangan sistem informasi persediaan yang dapat terintegrasi IoT agar menjadi *realtime stock monitoring*, serta dapat menampilkan hasil dari penelitian dalam bentuk web atau aplikasi.

Daftar Pustaka

- Amalia, T., Septiadi, M., Rafly, R., & Pranata, J. (2020). Analisis Perencanaan dan Pengendalian Produksi untuk Mengoptimalkan Biaya Produksi Ragum. *Jurnal Talenta*, 3(2), 265–272.
- Badrul, M., Studi, P., & Informasi, S. (2016). Algoritma Asosiasi dengan Algoritma Apriori untuk Analisa Data Penjualan. *Jurnal Pilar Nusa Mandiri*, XII, 121–129.
- Basuki. (2016). Optimasi Ukuran Pemesanan Lot Yang Ekonomis pada Permintaan Deterministik Dinamis Menggunakan Algoritma Wagner-Within. *Industrial Engineering Journal*, 5(1), 29–34.
- Bilaffayza, E. S., Wahyudin, W., & Herwanto, D. (2023). *Peramalan Permintaan Metode Moving Average dan Linier Regression dalam Memprediksi Produksi Produk Disc Brake K93 (Studi Kasus PT United Steel Center Indonesia)*. 10.
- Indriyani, F., & Irfiani, E. (2019). Clustering Data Penjualan pada Toko Perlengkapan Outdoor Menggunakan Metode K-Means. *JUITA : Jurnal Informatika*, 7(2), 109.
- Kurniawan, V. (2022). Analisis Persediaan Bahan Baku Pasir Besidi PT Semen Baturaja. *Multidisipliner Kapalamada*, 1(3), 406–411.
- Kusrini & Luthfi, E. T. (2009). *Algoritma Data Mining* (T. A. Prabawati (ed.)). CV Andi Offset.

- Mira Febrina, Faula Arina, R. E. (2013). Peramalan Jumlah Permintaan Produksi Menggunakan Jaringan Saraf Tiruan Algoritma Backpropagation. *Jurnal Teknik Industri*, 1(2), 174–179.
- Nasution, A. H., & Prasetyawan, Y. (2008). *Perencanaan dan Pengendalian Produksi*. Graha Ilmu.
- Rohana, B., Purba, B., & Ginting, G. L. (2018). Implementasi Algoritma Apriori untuk mencari Relasi pada Transaksi Pembelian Alat-Alat Kesehatan (Studi Kasus: RS. ESTOMIH). 5.
- Sri Kusumadewi. (2004). *Membangun Jaringan Syaraf Tiruan Menggunakan MATLAB & EXCEL LINK*. Yogyakarta: Graha Ilmu.
- Thoriq, M. (2022). Peramalan Jumlah Permintaan Produksi Menggunakan Jaringan Saraf Tiruan Algoritma Backpropagation. *Jurnal Informasi Dan Teknologi*, 1(2), 27–32.
- Windarto, Agus Perdana, D. (2020). *Jaringan Saraf Tiruan: Algoritma Prediksi dan Implementasi* (J. Simarmata (ed.); (Cetakan 1). Yayasan Kita Menulis.