

SIDANG AKHIR TA



LAB RDIB , 4 Mei 2016

JUDUL



ITS
Institut
Teknologi
Sepuluh Nopember



PERAMALAN JUMLAH PENJUALAN NOTA DI CV. GEMILANG INDONESIA DENGAN MENGGUNAKAN ARTIFICIAL NEURAL NETWORK (ANN)

Oleh :
Ari Dwi Ningsih
5212100032

Dosen Pembimbing I
Edwin Riksakomara, S.Kom., M.T.

OUTLINE



ITS
Institut
Teknologi
Sepuluh Nopember



sistem
informasi
fakultas teknologi
informasi

Pendahuluan

Tinjauan
Pustaka

Metodologi

Jadwal Kegiatan

Daftar
Pustaka

- CV. Gemilang Indonesia merupakan perusahaan yang bergerak dibidang jasa percetakaan yang terletak di Sidoarjo. Produk yang dihasilkan antara lain, Cetak Nota, Cetak Faktur, Cetak Stiker dll
- Daerah pemasaran produk CV.Gemilang Indonesia tersebar di Jawa Timur, Bali, Sumatera dan Kalimantan dengan pelanggannya terdiri dari 90% perusahaan dan 10% dari perorangan
- Terdapat produk yang dipesan dengan design tertentu namun juga terdapat produk yang memiliki design umum

Permasalahan

- Barang atau produk sering mengalami Out of Stock (kehabisan stok)
- Barang atau produk sering mengalami Over Capacity (kelebihan produk)
- Permintaan pasar yang tidak menentu
- Keterbatasan gudang penyimpanan material dan produk jadi

Solusi

- Melakukan Peramalan Penjualan Nota Di CV. Gemilang Indonesia

Metode

ANN

Backpropagation

1. Model seperti apakah yang cocok untuk meramalkan penjualan nota dalam periode waktu ke depan di CV.Gemilang Indonesia ?
2. Bagaimana Backpropagation Neural Network dapat menyelesaikan permasalahan penjualan di CV.Gemilang Indonesia ?
3. Bagaimanakah performa atau kinerja *Backpropagation Neural Network* dalam melakukan peramalan ?

1. Data yang digunakan dalam penelitian tugas akhir ini merupakan data penjualan nota selama periode waktu (*time series*) mingguan selama tahun 2014-2015
2. Metode peramalan yang digunakan yaitu *Backpropagation Neural Network*
3. Penelitian dilakukan di CV.Gemilang Indonesia.

PENDAHULUAN

TUJUAN



ITS
Institut
Teknologi
Sepuluh Nopember



sistem
informasi
fakultas teknologi
informasi

Untuk meramalkan jumlah penjualan nota untuk beberapa periode waktu yang akan datang dengan melibatkan beberapa faktor atau variabel yang mempengaruhinya.



1. Dapat mengetahui pola penjualan nota di CV. Gemilang Indonesia
2. Dapat mengetahui jadwal produksi yang tepat agar produk yang tersedia dapat memenuhi permintaan pelanggan.
3. Dapat mengetahui kebutuhan material untuk setiap produk yang akan diproduksi.
4. Dapat mengetahui jadwal pengadaan material
5. Dapat mengelola stock material maupun produk jadi yang terdapat di gudang (*inventory*)

Untuk meramalkan jumlah penjualan nota untuk beberapa periode waktu yang akan datang dengan melibatkan beberapa faktor atau variabel yang mempengaruhinya.

3. Dapat mengetahui kebutuhan material untuk setiap produk yang akan diproduksi.

~~penjadwalan pengadaan barang dan jasa~~.

4. Dapat mengetahui jadwal pengadaan material

~~dagang atau takait pertama atau ketiga bukropugutir caturdewata atau~~

5. Dapat mengelola stock material maupun produk jadi yang terdapat di gudang (*inventory*)

domain ***INTELLEGENCE SYSTEM***
topik ***ARTIFICIAL INTELLEGENCE***

TEKNIK PERAMALAN

TINJAUAN PUSTAKA

PENELITIAN SEBELUMNYA



sistem
informasi
fakultas teknologi
informasi

Judul	Hasil Penelitian	Kelebihan	Kekurangan
Peramalan penjualan Produk Susu Bayi dengan Metode Grey	memiliki pola data acak dengan menggunakan berbagai metode peramalan. Dari hasil penelitian terbukti bahwa metode Neural Network cocok untuk peramalan penjualan dengan pola data yang tidak menentu (acak) yang menghasilkan peramalan lebih akurat.	penjualan dengan pola data acak lebih akurat disbanding metode lainnya	terendah dan terbesar pada data.
System Theory dan Neural Network [11]			

Peramalan

Peramalan merupakan perkiraan atau prediksi di masa depan berdasarkan data di masa lalu atau data historis

peramalan yang melibatkan pendapat para ahli, biasanya menggunakan metode Delphi

digunakan pada saat data masa lalu cukup tersedia. Beberapa teknik kuantitatif yang sering dipergunakan: *Time Series Model* dan *Causal Model*.

Perhitungan Error

MAD

(*Mean Absolute Deviation*) merupakan perhitungan error dimana nilainya dihitung dengan mengambil jumlah nilai absolut dari setiap kesalahan peramalan dibagi dengan jumlah periode data (n)

MSE

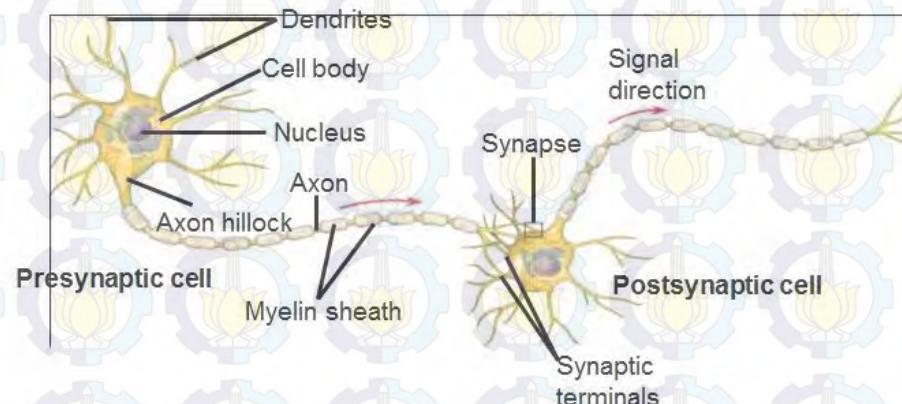
(*Mean Squared Error*) merupakan perhitungan error dengan menggunakan rataan selisih kuadrat antara nilai yang diramalkan dan yang diamati

MAPE

(*Mean Absolute Percentage Error*) merupakan perhitungan error dengan menggunakan rataan deferensial absolut antara nilai yang diramalkan dan aktual, dinyatakan sebagai persentase nilai aktual, jika memiliki nilai yang diramalkan untuk n periode

ANN

sebuah sistem untuk pemrosesan informasi dengan “meniru” cara kerja sistem saraf biologis. ANN terinspirasi dari sistem kerja saraf manusia yang disebut *neuron*



ANN

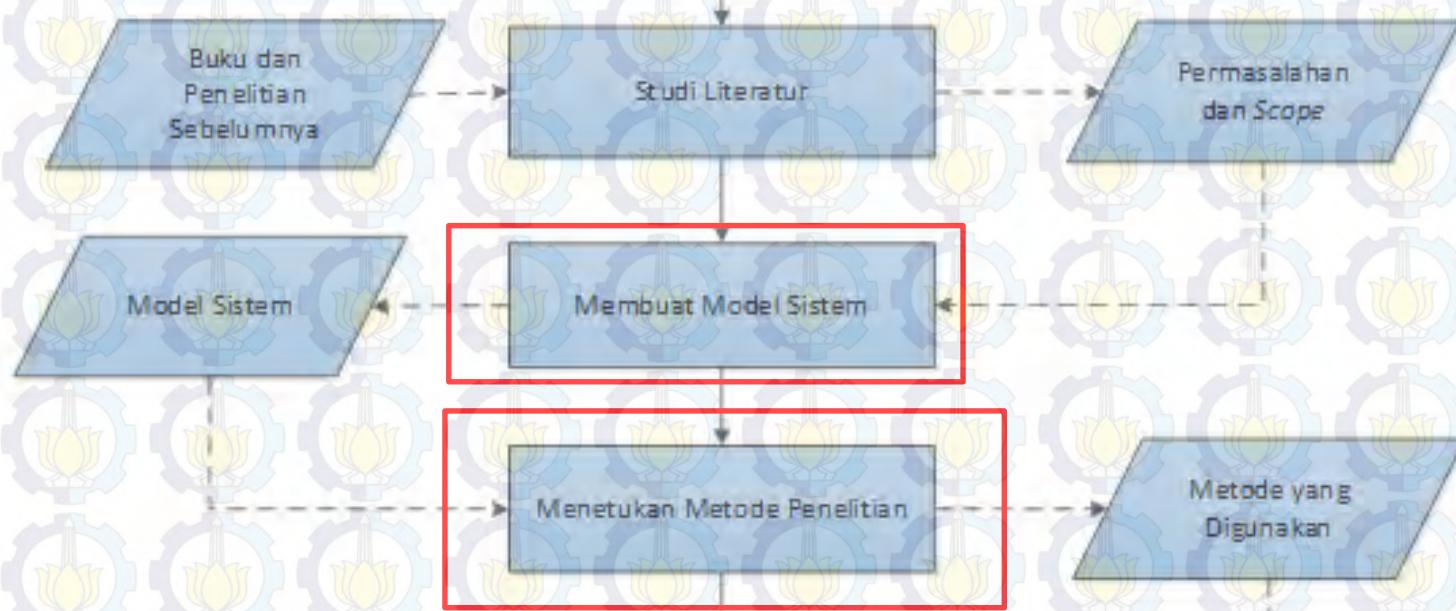
Backpropagation

Dasar pemikiran :

- Membutuhkan data training
- Variabel input dan output
- Membutuhkan pembobotan

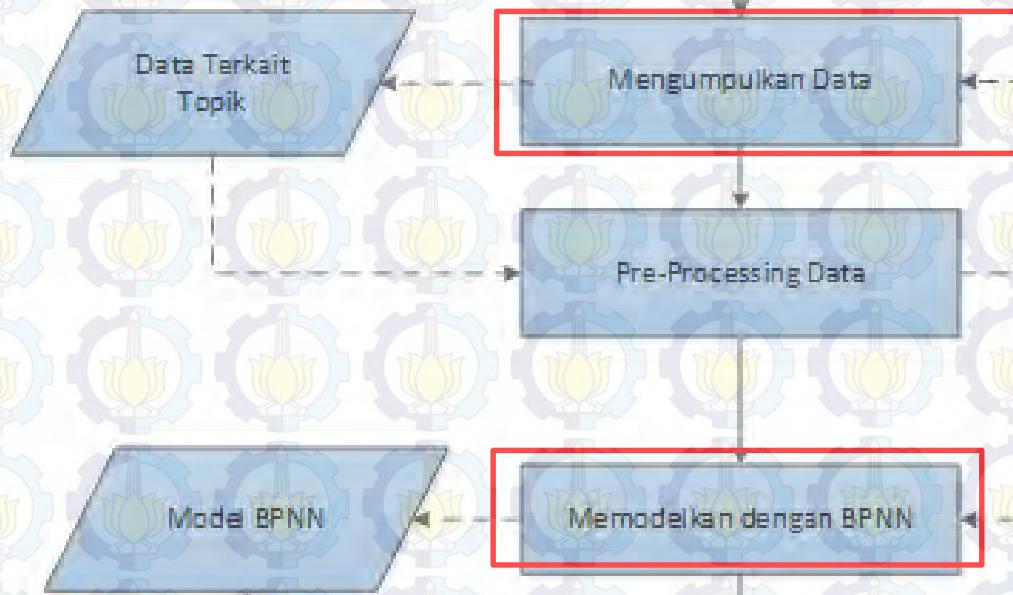
METODOLOGI

Tahap Persiapan



Mencari variabel-variabel terkait antara lain data penjualan dan *time series* yang digunakan dalam peramalan

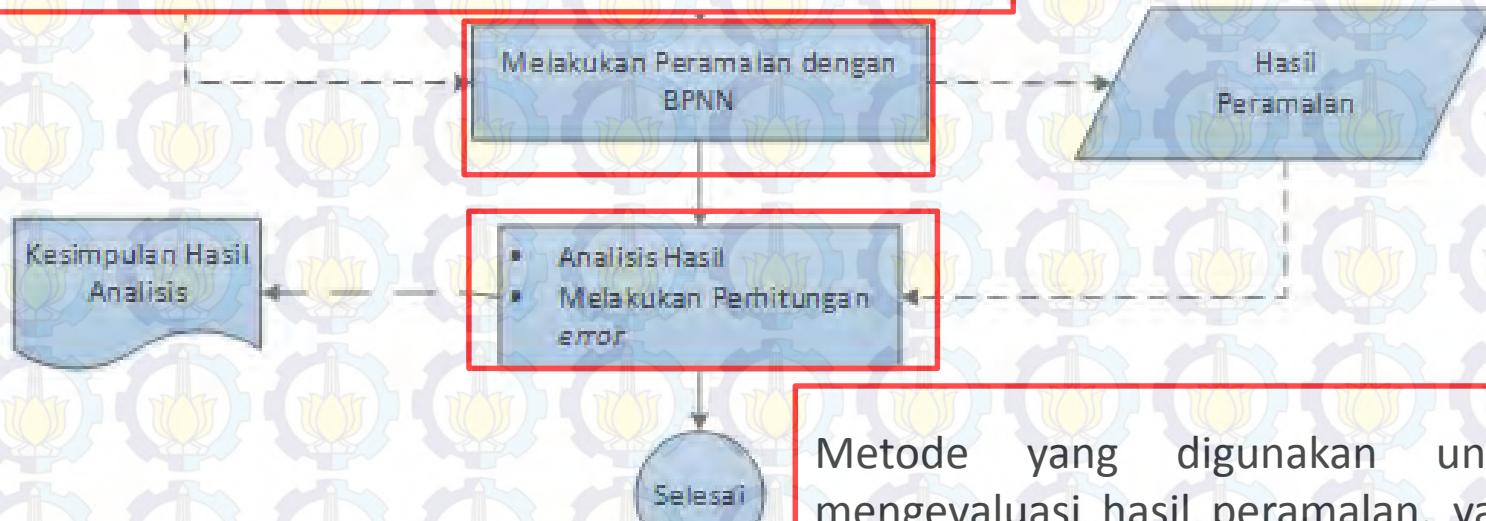
Menggali kelebihan dan kelemahan dari studi literatur, kesesuaian dengan topik permasalahan yang diangkat dan data yang ada



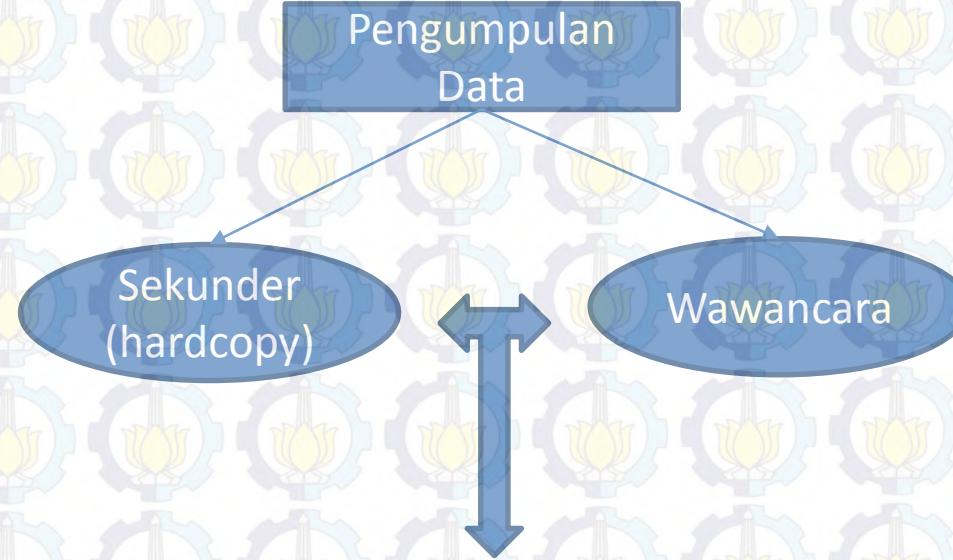
Data yang diambil berdasarkan model system yang dibuat, kemudian dikumpulkan dari hasil wawancara dan observasi dokumen CV. Gemilang Indonesia

Dimodelkan berdasarkan Backpropagation dengan input data penjualan, hidden layer menggunakan sigmoid dan output menggunakan aktivasi linear

Data yang digunakan untuk peramalan yaitu data penjualan nota CV.Gemilang Indonesia. Data test digunakan untuk mengetahui keakuratan kegiatan peramalan terhadap data baru di luar data sampel



Metode yang digunakan untuk mengevaluasi hasil peramalan, yaitu MAPE. Dari perhitungan error tersebut akan diketahui seberapa akurat hasil peramalan penjualan nota di CV.Gemilang Indonesia.

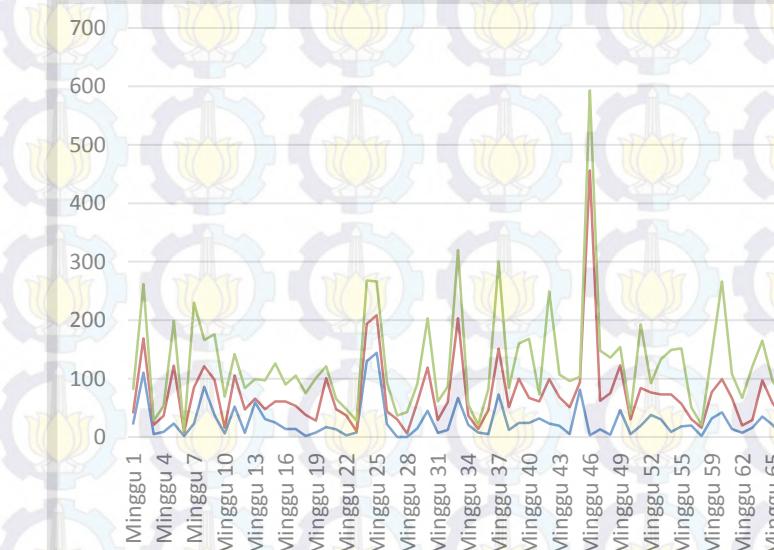


Data masukan berupa data penjualan nota dalam mingguan selama Juni 2014 – Februari 2016.

Pada minggu 57 terdapat nilai 0 (kosong yang artinya pada minggu tersebut tidak terdapat record penjualan). Hal ini dikarenakan pada tanggal minggu tersebut merupakan hari libur lebaran dan perusahaan diliburkan sehingga record penjualan dilaporkan pada minggu berikutnya.

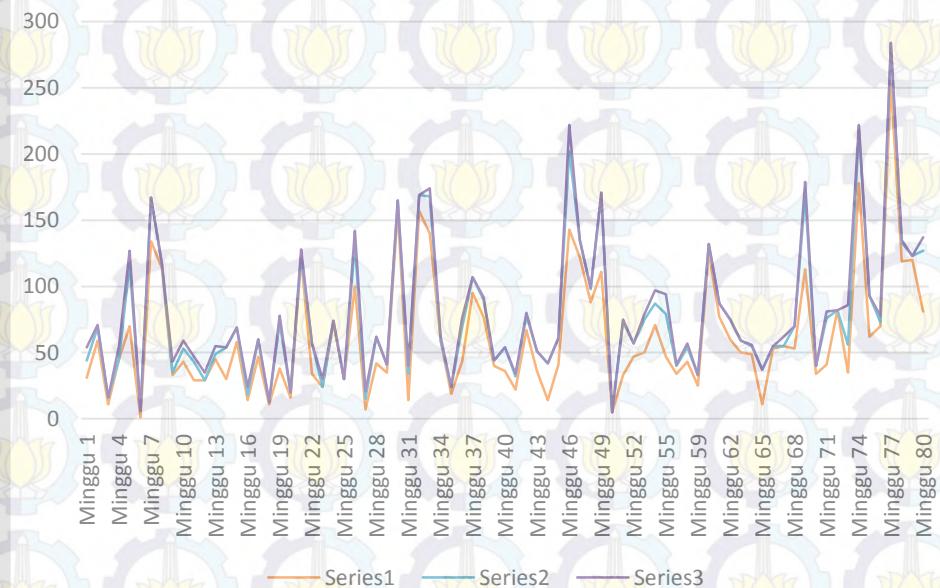


Metode menghilangkan data kosong secara manual dari data penjualan nota. Hal ini dilakukan karena hanya terdapat 1 nilai saja yang kosong yaitu ada Minggu 57 merupakan tanggal 19-25 Juli 2015, sehingga jika data tersebut dihilangkan tidak akan terlalu mempengaruhi pola data.



Keterangan :

- : Nota K1 (jenis nota dengan 1 layer)
- : Nota K2 (jenis nota dengan 2 layer)
- : Nota K3 (jenis nota dengan 2 layer)
- : Nota K4 (jenis nota dengan 4 layer)
- : Nota K5 (jenis nota dengan 5 layer)
- : Nota K6 (jenis nota dengan 6 layer)



Model JST

Dengan 8 model

Dan 6 produk K1, K2, K3, K4,
K5 dan K6

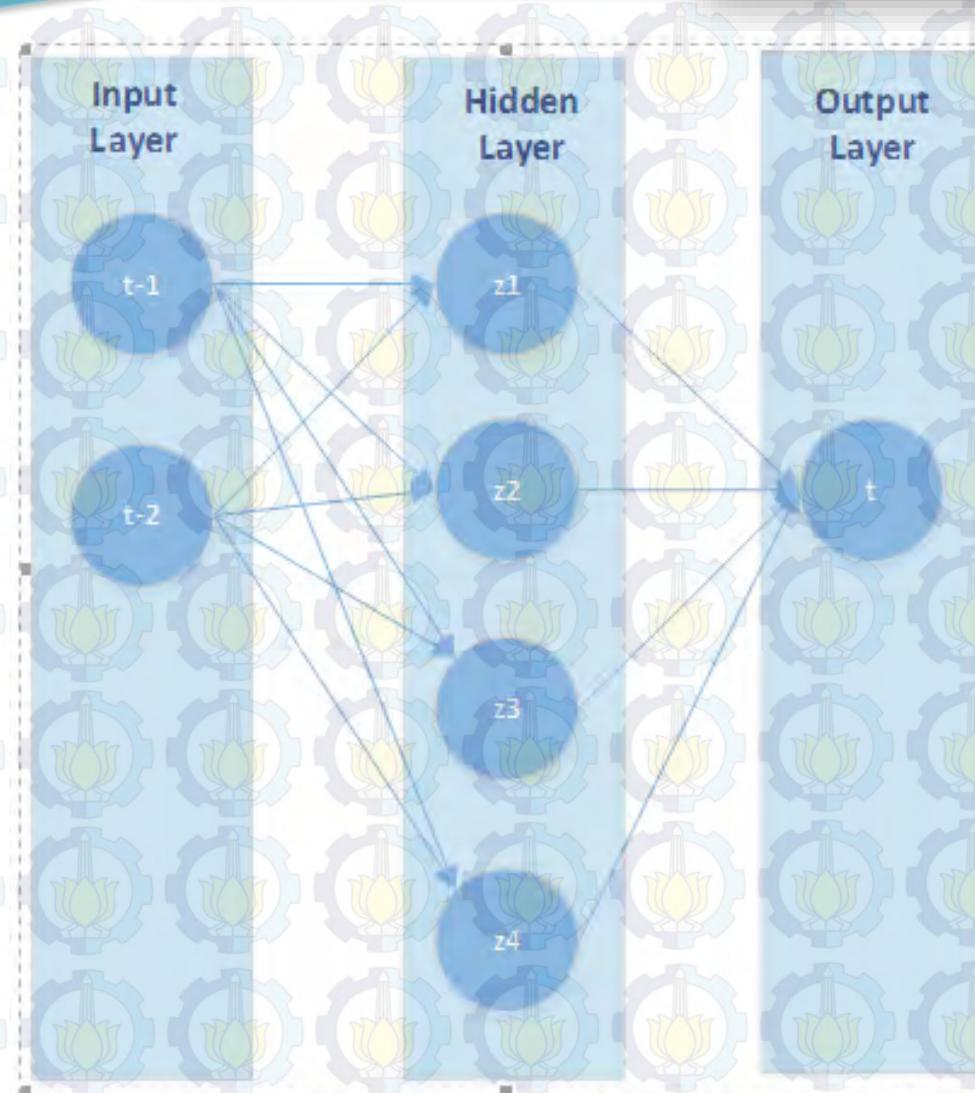
Time Series (melihat beberapa minggu kebelakang)

input layer

Hidden layer = 2*input layer

1 output layer

$$y(t) = f(y_{(t-1)}, \dots, y_{(t-n)})$$



1. Menggunakan 79 entri data penjualan nota
2. Membagi data menjadi dua bagian yaitu data *training* dan data *testing*
3. Menggunakan perbandingan 70:30

Normalisasi digunakan untuk meng-skalakan data (range sama) dengan mean = 0 dan standar deviasi = 1

$$[pn, \text{meanp}, \text{stdp}, tn, \text{meant}, \text{stdt}] = \text{prestd}(p, t)$$

Dimana :

- p = matriks input training
- t = matriks target
- pn = matriks input yang ternormalisasi
- tn = matriks target yang ternormalisasi
- meanp = rata rata pada matriks input (p)
- stdp = standard deviasi pada matriks input (p)
- meant = rata rata pada matriks target (t)
- stdt = standard deviasi pada matriks target (t)

```
net=newff(minmax(pn), [x, y], {'logsig', 'purelin'},  
'traingdx');
```

Dimana :

pn = matriks input yang ternormalisasi

x = node hidden layer

y = node output layer

Logsig = fungsi aktivasi sigmoid bipolar

Purelin = fungsi aktivasi linear

Traingdx = mengkombinasikan learning rate dengan momentum saat training

```
net.trainParam.EPOCHS = a;  
net.trainParam.lr = b;  
net.trainParam.mc = c;
```

dimana

a : diisi dengan jumlah iterasi (epoch)

b : diisi dengan nilai learning rate (lr)

c : diisi dengan nilai momentum (mc)

```
net = train(net,pn,tn);
```

dimana

net : model jaringan saraf yang sudah dibangun

pn : matriks input jaringan saraf yang ternormalisasi

tn : matriks target jaringan saraf yang ternormalisasi

Proses *training* dilakukan sebanyak 3 kali karena bobot pada masing-masing parameter pasti berubah. Kemudian dipilih performa terbaik pada proses pelatihan yang dilihat berdasarkan nilai MAPE terkecil

Simulasi bertujuan untuk menghasilkan output jaringan dari model jaringan dan input matrik

$$S = \text{sim}(\text{net}, \text{pn})$$

dimana

S : output jaringan saraf

net : model jaringan saraf

pn = matriks input jaringan saraf yang ternormalisasi

Output yang dihasilkan pada proses simulasi *training* perlu diubah ke bentuk denormalisasi, proses ini disebut *Postprocessing*

```
d =poststd(an,meant,stdt)
```

dimana

d : nilai output denormalisasi training

s : nilai output simulasi

meant : rata rata matriks target asli (t)

stdt : standar deviasi pada matriks target asli (t).

Data testing di normalisasi terlebih dahulu dengan fungsi *trastd*.

$$qn = \text{trastd}(q, \text{meanp}, \text{stdp})$$

dimana

qn : data testing ternormalisasi

q : data testing

meanp : mean dari proses normalisasi data pelatihan

stdp : nilai standar deviasi dari proses normalisasi data pelatihan

Data testing yang sudah ternormalisasi di simulasi dengan perintah sim menggunakan model jaringan pada proses training untuk menghasilkan output yang diinginkan

$$sq = \text{sim}(\text{net}, qn)$$

dimana

sq : data output hasil testing

net : jaringan pada proses training

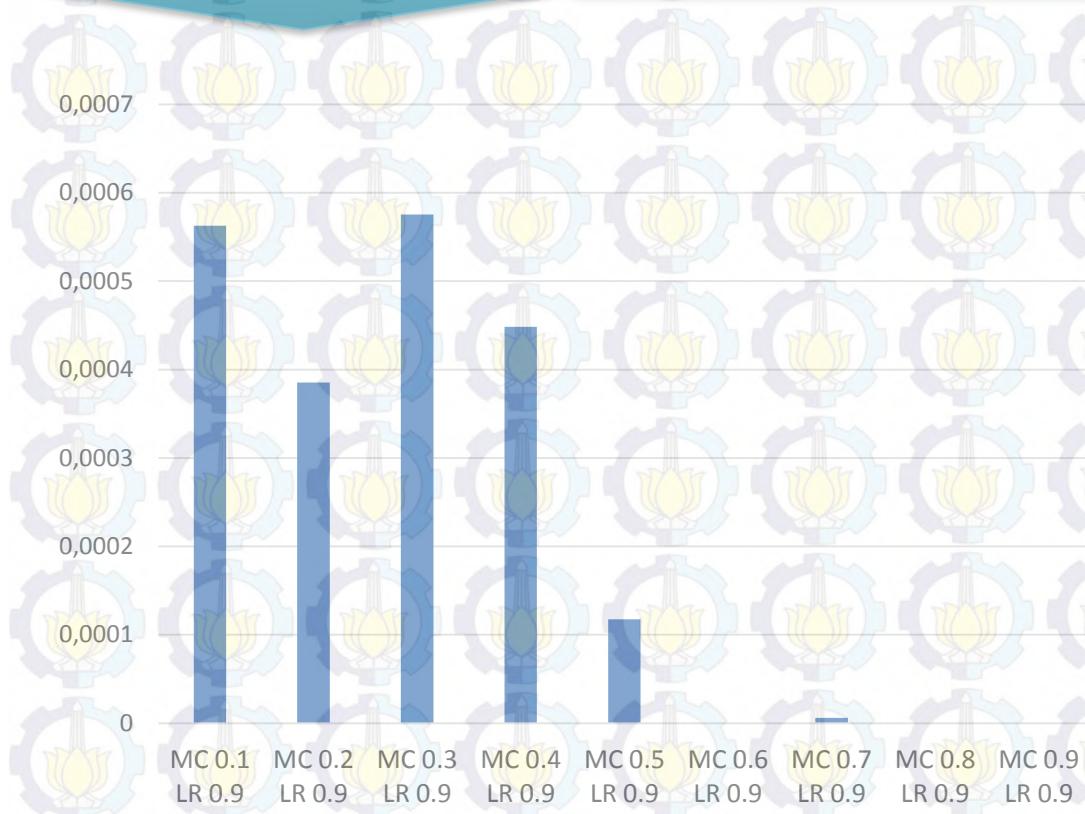
qn : data testing

Data testing di normalisasi terlebih dahulu dengan fungsi *trastd*.

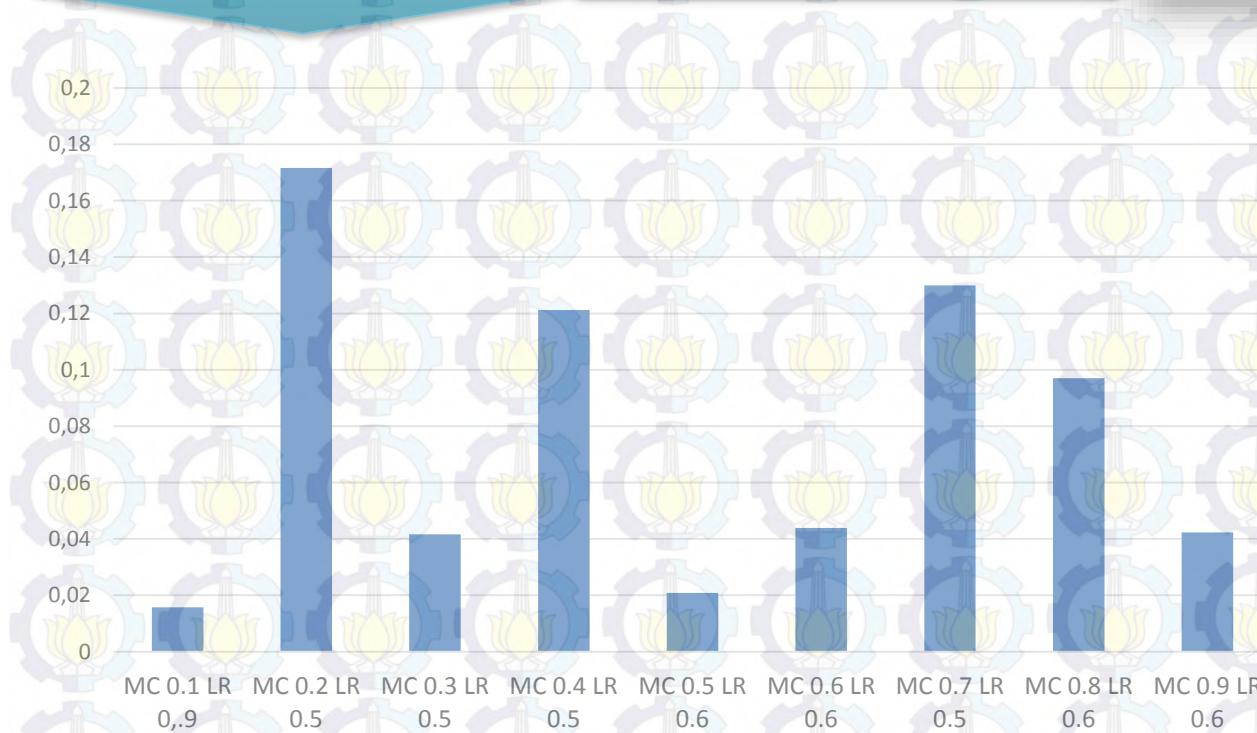
$$dq = \text{poststd}(bn, meant, stdt)$$

dimana

- dq : data output testing yang ternormalisasi
- sq : data output hasil testing
- meant : nilai mean dari proses normalisasi
- stdt : nilai standar deviasi dari proses normalisasi



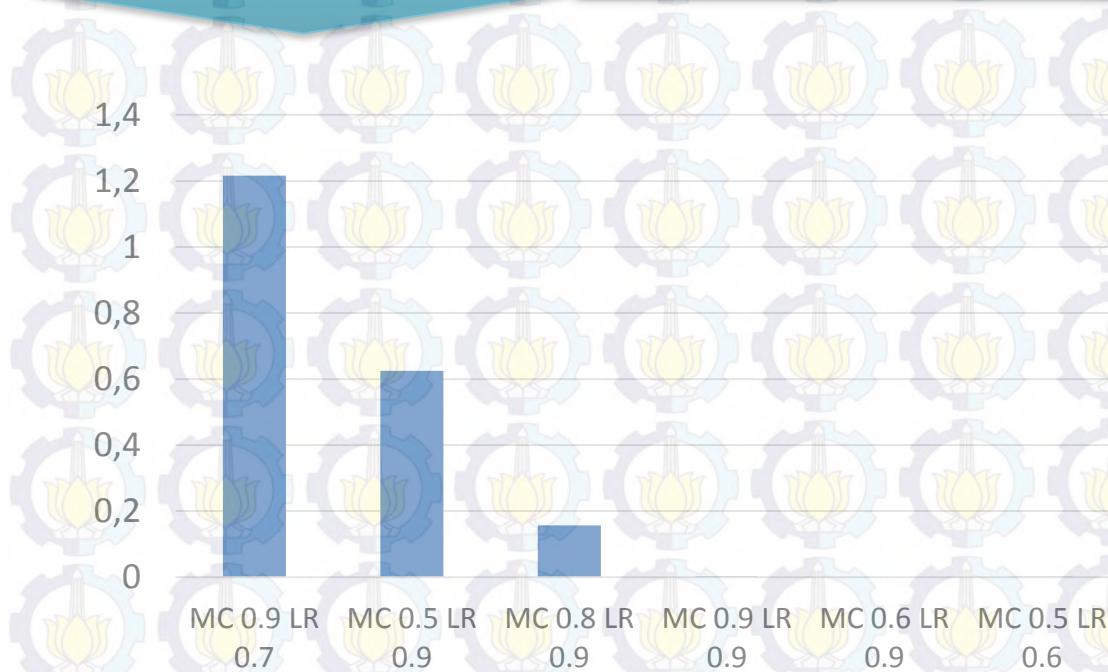
Dari diatas terlihat bahwa nilai MAPE untuk KUM8 berubah secara fluktuatif. Nilai MAPE yang paling tinggi yaitu parameter dengan (mc 0.3 lr 0.9) sebesar $0.000575218 \cong 0.058\%$. Sedangkan nilai MAPE yang paling kecil yaitu parameter dengan *momentum* 0.6 dan *learning rate* 0.9 sebesar $1.56E-09 \cong 0.00000016\%$.



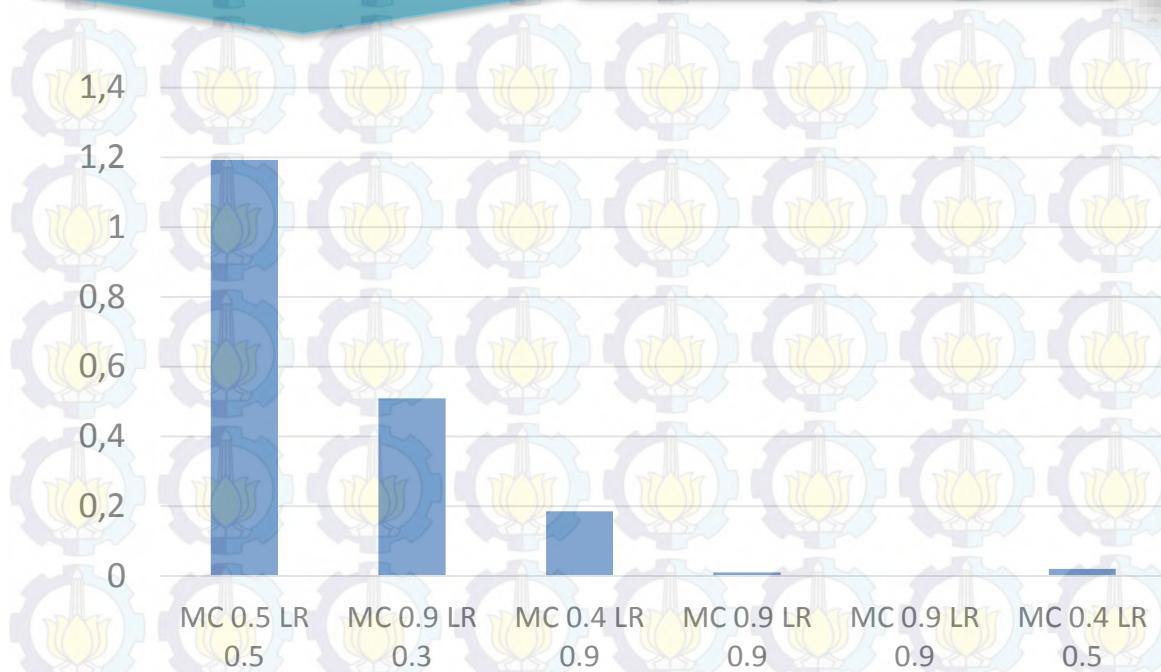
Pada Gambar 6.16 dapat diketahui bahwa nilai MAPE pada produk K1 (Nota 1 Layer) mengalami kenaikan dan penurunan secara fluktuatif. MAPE paling kecil yaitu pada JST 5. Namun pada JST 6 nilai MAPE naik kembali, sehingga model yang paling optimal pada produk K1 yaitu model K1M5 (JST 5) parameter *momentum* 0.8 dan *learning rate* 0.9 dengan nilai MAPE sebesar $0.000109859 \approx 0.011\%$.



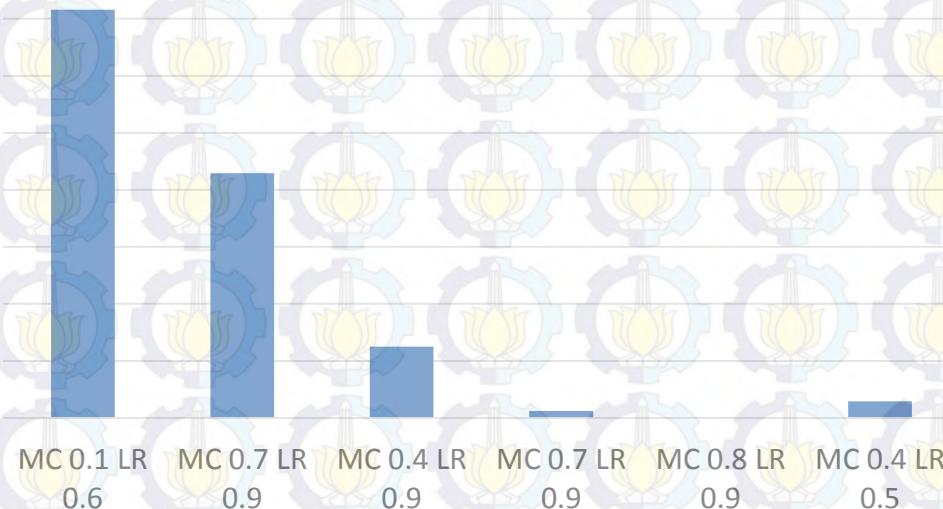
Pada gambar diatas dapat diketahui bahwa untuk produk K2 (Nota 2 Layer) nilai MAPE semakin turun dari JST 1 ke JST 5, namun mengalami kenaikan pada JST 6. Sehingga model yang paling optimal K2M5 (JST 5) parameter *momentum* 0.7 dan *learning rate* 0.9 dengan nilai MAPE sebesar $0.016558448 \cong 1.65\%$.



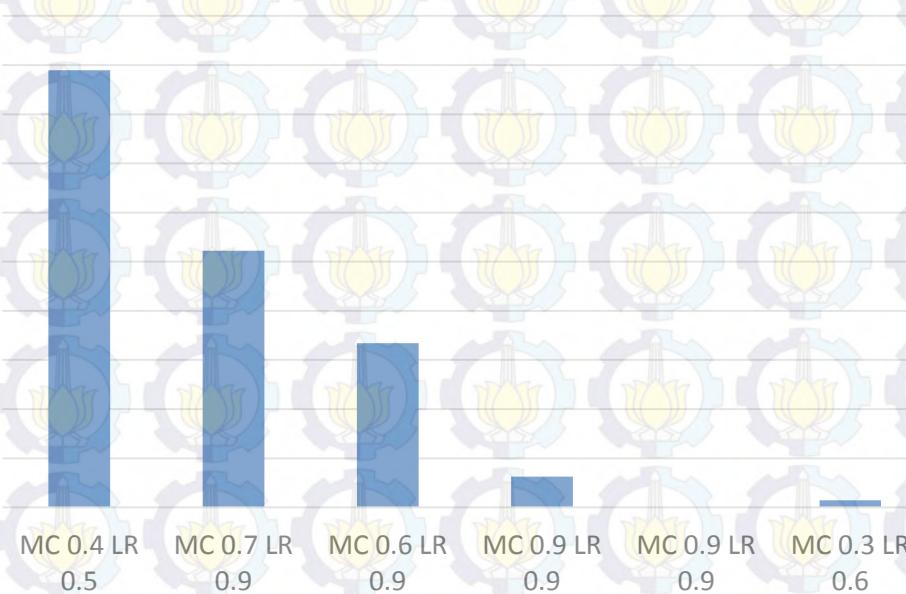
Pada Gambar 6.30 dapat diketahui bahwa untuk produk K3 (Nota 3 Layer) nilai MAPE semakin turun dari JST 1 ke JST 5, sehingga hasil peramalan semakin mendekati target. Namun, nilai MAPE pada JST 5 ke JST 6 naik kembali. Sehingga, model yang paling optimal pada produk K3 yaitu model K3M5 (JST 5) parameter *momentum* 0.6 dan *learning rate* 0.9 dengan nilai MAPE sebesar $3.51017E-08 \cong 0.0000035\%$.



Pada gambar diatas dapat diketahui bahwa untuk produk K4 (Nota 4 Layer) nilai MAPE semakin turun dari JST 1 ke JST 5, sehingga hasil peramalan semakin mendekati target. Namun, nilai MAPE pada JST 5 ke JST 6 mengalami kenaikan. Sehingga model yang paling optimal pada produk K4 yaitu model K4M5 (JST 5) parameter dengan *momentum* 0.9 dan *learning rate* 0.9 dengan nilai MAPE sebesar $7.99998E-06 \cong 0.0008\%$.



Pada diatas dapat diketahui bahwa untuk produk K5 (Nota 5 Layer) nilai MAPE semakin turun dari JST 1 ke JST 5, sehingga hasil peramalan semakin mendekati target. Namun nilai MAPE naik pada JST 6. Sehingga, model yang paling optimal pada produk K5 yaitu model K5M5 (JST 5) parameter *momentum* 0.8 dan *learning rate* 0.9 dengan nilai MAPE sebesar $0.000125351 \approx 0.0125\%$



Pada diatas dapat diketahui bahwa untuk produk K6 (Nota 6 Layer) nilai MAPE semakin turun dari JST 1 ke JST 5, sehingga hasil peramalan semakin mendekati target. Namun, nilai MAPE pada JST 6 kembali naik . Sehingga model yang paling optimal pada produk K6 yaitu model K6M5 (JST 5) parameter *momentum* 0.9 dan *learning rate* 0.9 dengan nilai MAPE sebesar $1.40459E-09 \cong 0.00000014\%$

Model	MC	LR	Training	Testing
KUM1	0.4	0.5	0.6084677581 ≈ 60.84%	0.155916323 ≈ 15.59%
KUM2	0.8	0.6	0.45273929 ≈ 45.27%	0.027086971 ≈ 2.71%
KUM3	0.9	0.5	0.157582005 ≈ 15.75%.	4.20582E – 06 ≈ 0.000421%
KUM4	0.4	0.7	0.066133689 ≈ 6.61%	6.59969E – 05 ≈ 0.007%
KUM5	0.1	0.5	0.039498302 ≈ 3.94%.	6.04606E – 05 ≈ 0.006%
KUM6	0.2	0.5	0.01125293870 ≈ 1.1218%	3.51021E – 06 ≈ 0.000351%
KUM7	0.5	0.7	0.001299218 ≈ 0.1299%.	1.02555E – 10 ≈ 0.0000000103%
KUM8	0.6	0.9	1.56E – 09 ≈ 0.00000016%	7.65758E – 11 ≈ 0.0000000077%

Model	MC	LR	Training	Testing
K1M1	0.7	0.9	0.4016107368 ≈ 40.16%	0.240734651 ≈ 24.07%
K1M2	0.5	0.7	1.146031251 ≈ 114.603%	0.097823278 ≈ 9.78%
K1M3	0.9	0.9	0.401302282 ≈ 40.13%	0.000607107 ≈ 0.061%
K1M4	0.8	0.9	0.034227311 ≈ 3.42%	1.02708E – 05 ≈ 0.00103%
K1M5	0.8	0.9	0.000109859 ≈ 0.011%	7.98594E – 08 ≈ 0.000008%
K1M6	0.1	0.9	0.015796036 ≈ 1.58%	0.000134645 ≈ 0.013%

PEMBAHASAN

Uji Coba Produk K2



ITS
Institut
Teknologi
Sepuluh Nopember



sistem
informasi
fakultas teknologi
informasi

Model	MC	LR	Training	Testing
K2M1	0.2	0.5	1.423189387 $\cong 142.32\%$	0.55489353 $\cong 55.49\%$
K2M2	0.8	0.9	0.89854733 $\cong 89.85\%$	0.286241455 $\cong 28.62\%$
K2M3	0.9	0.9	0.486589698 $\cong 48.6\%$	0.020020567 $\cong 2.002\%$
K2M4	0.8	0.9	0.192708186 $\cong 19.27\%$	2.34705E – 09 $\cong 0.00000023\%$
K2M5	0.7	0.9	0.16558448 $\cong 16.55\%$	4.32248E – 08 $\cong 0.00000432\%$
K2M6	0.1	0.6	0.229941264 $\cong 22.99\%$	0.001428461 $\cong 0.14\%$

Model	MC	LR	Training	Testing
K3M1	0.9	0.7	1.216305481 $\cong 121.63\%$	0.007982772 $\cong 0.798\%$
K3M2	0.5	0.9	0.62459656 $\cong 62.45\%$	0.118542531 $\cong 11.85\%$
K3M3	0.8	0.9	0.156712342 $\cong 15.67\%$	0.004665399 $\cong 0.47$
K3M4	0.9	0.9	0.002990031 $\cong 0.299\%$	0.001121924 $\cong 0.11\%$
K3M5	0.6	0.9	$3.51017E - 08$ $\cong 0.00000351\%$	$2.7492E - 05$ $\cong 0.0027\%$
K3M6	0.5	0.6	0.001603827 $\cong 0.16\%$	$2.46379E - 07$ $\cong 0.000025\%$

Model	MC	LR	Training	Testing
K4M1	0.5	0.5	1.192126142 ≈ 119.21%	0.701320137 ≈ 7.13%
K4M2	0.9	0.3	0.508732399 ≈ 50.87%	0.292263973 ≈ 29.23%
K4M3	0.4	0.9	0.184927041 ≈ 18.49%	0.074674542 ≈ 7.47%
K4M4	0.9	0.9	0.0097916622 ≈ 0.98%	0.005810863 ≈ 0.58%
K4M5	0.9	0.9	7.99998E – 06 ≈ 0.000799%	2.1733E – 05 ≈ 0.0022%
K4M6	0.4	0.5	0.02031934 ≈ 2.03%	3.36115E – 05 ≈ 0.00336%

Model	MC	LR	Training	Testing
K5M1	0.1	0.6	0.715835814 ≈ 71.58%	0.726992711 ≈ 72.70%
K5M2	0.7	0.9	0.429053143 ≈ 42.90%	0.123670959 ≈ 12.37%
K5M3	0.4	0.9	0.12142197 ≈ 12.14%	0.071667901 ≈ 7.17%
K5M4	0.7	0.9	0.011938037 ≈ 1.19%	0.006594905 ≈ 0.66%
K5M5	0.8	0.9	0.000125351 ≈ 0.0125%	0.000268682 ≈ 0.027%
K5M6	0.4	0.5	0.029246984 ≈ 2.92%	0.000716206 ≈ 0.07%

Model	MC	LR	Training	Testing
K6M1	0.4	0.5	0.444706276 ≈ 44.47%	0.396648777 ≈ 39.66%
K6M2	0.7	0.9	0.261070141 ≈ 26.10%	0.207785531 ≈ 20.78%
K6M3	0.6	0.9	0.167104027 ≈ 16.71%	0.120365341 ≈ 12.04%
K6M4	0.9	0.9	0.031161651 ≈ 3.11%	0.154490772 ≈ 15.45%
K6M5	0.9	0.9	$1.40459E - 09$ ≈ 0.00000014%	0.079135192 ≈ 7.91%
K6M6	0.3	0.6	0.007095486 ≈ 0.709%	0.08000342 ≈ 8.00%

KESIMPULAN



ITS
Institut
Teknologi
Sepuluh Nopember



sistem
informasi
fakultas teknologi
informatika

Berdasarkan proses penelitian yang telah dilakukan, berikut ini merupakan kesimpulan yang dapat diambil :

- a) Model terbaik yang dapat digunakan dalam peramalan penjualan produk-produk nota di CV. Gemilang Indonesia adalah dengan variabel input sebanyak 5 node, variabel hidden layer sebanyak 10 node dan output layer sebanyak 1 node dengan parameter optimal yaitu epoch sebesar 1000.
- b) Belum terdapat model yang paling optimal pada produk Akumulasi dikarenakan nilai MAPE terus mengecil.
- c) Parameter yang paling optimal untuk peramalan yaitu sebagai berikut :
 - produk K1 (Nota 1 Layer) yaitu momentum 0.8 dan learning rate 0.9
 - produk K2 (Nota 2 Layer) yaitu momentum 0.7 dan learning rate 0.9
 - produk K3 (Nota 3 Layer) yaitu momentum 0.6 dan learning rate 0.9
 - produk K4 (Nota 4 Layer) yaitu momentum 0.9 dan learning rate 0.9
 - produk K5 (Nota 5 Layer) yaitu momentum 0.8 dan learning rate 0.9
 - produk K6 (Nota 6 Layer) yaitu momentum 0.9 dan learning rate 0.9

KESIMPULAN



- d) Proses *training* dan *testing* perlu dilakukan setidaknya 3-5 kali pada setiap parameter untuk mengetahui hasil terbaik. Hal ini dikarenakan bobot pada *neural network* berubah-ubah.
- e) Semakin banyak jumlah input maka hasil peramalan akan semakin optimal. Namun jika nilai MAPE telah konvegen atau nak kembali maka proses training dihentikan
- f) Metode Artificial Neural Network dapat diterapkan untuk peramalan penjualan nota di CV. Gemilang Indonesia.
- g) Model Yang paling optimal yaitu dengan 5 input (5 minggu sebelumnya)
- h) Tingkat akurasi yang didapatkan dari rata rata error perbandingan data aktual dan data peramalan(MAPE) menggunakan ANN untuk semua produk yaitu kurang dari 8%.

SARAN



ITS
Institut
Teknologi
Sepuluh Nopember



sistem
informasi
fakultas teknologi
informasi

Saran yang dihasilkan dari penarikan kesimpulan dan batasan masalah dari penggerjaan tugas akhir ini adalah sebagai berikut :

1. Dalam penelitian ini , proses pelatihan dan pengujian menggunakan tools matlab dengan kode terpisah sehingga memerlukan waktu yang cukup lama dalam prosesnya. Selain itu, metode mencari nilai MAPE masih dilakukan secara manual menggunakan MS.Excel. Untuk itu, pada penelitian selanjutnya dapat dikembangkan sebuah aplikasi untuk peramalan sekaligus untuk mencari nilai MAPE nya.
2. Dapat digunakan Metode Neural Network selain backpropagation, seperti adaptive smoothing neural network atau feed forward neural network dalam penelitian selanjutnya untuk mengetahui perbandingan performa dalam hasil peramalan.

DAFTAR PUSTAKA



- [1] H. Jiang, C. Kwong, K. Siu and Y. Liu, "Rough set and PSO-based ANFIS approaches to modeling customer satisfaction for affective product design," *Advanced Engineering Informatics*, p. 12, 2015.
- [2] H. Wang, B. Chen and H. Yan, "Optimal inventory decisions in a multiperiod newsvendor problem with partially observed Markovian supply capacities," *European Journal of Operational Research*, p. 16, 2010.
- [3] D. Papakiriakopoulos, "Predict on-shelf product availability in grocery retailing with classification methods," *Expert Systems with Applications*, p. 10, 2012.
- [4] Y. G. Zhong and Y. W. Zhou, "Improving the supply chain's performance through trade credit under inventory-dependent demand and limited storage capacity," *International Journal of Production Economics*, p. 7, 2013.
- [5] B. E. Saputra, Interviewee, *Proses Bisnis dan Profil CV.Gemilang Indonesia*. [Interview]. 30 September 2015.
- [6] D. Wang, O. Tang and L. Zhang, "A periodic review lot sizing problem with random yields, disruptions and inventory capacity," *International Journal of Production Economics*, p. 10, 2014.
- [7] Z. L. Sun, T. M. Choi, K. F. Au and Y. Yu, "Sales forecasting using extreme learning machine with applications in fashion retailing," *Decision Support Systems*, p. 9, 2008.
- [8] S. S. Loupatty, "Penerapan Jaringan Saraf Tiuran untuk Prediksi Biaya Pelayanan Rumah Sakit pada Pasien Peserta BPJS di Rumah Sakit Jiwa Menur Surabaya," 2015.
- [9] P. Doganis, A. Alexandridis, P. Patrinos and H. Sarimveis, "Time series sales forecasting for short shelf-life food products based on artificial neural networks and evolutionary computing," 2006.
- [10] S. E. Lestari, R. Astuti and S. Anggarini, "Perbandingan Peramalan Permintaan Keripik Nanas Menggunakan Metode Jaringan Syaraf Tiruan dan Time Series di UKM ‘So Kressh’ Malang," p. 8, 2014.
- [11] L. Stepvhanie, "Peramalan penjualan Produk Susu Bayi dengan Metode Grey System Theory dan Neural Network," 2012.

DAFTAR PUSTAKA



ITS
Institut
Teknologi
Sepuluh Nopember



sistem
informasi
fakultas teknologi
informasi

- [12] A. Krismundarto, Interviewee, *Kondisi Kekinian CV.Gemilang Indonesia*. [Interview]. 3 Oktober 2015.
- [13] Muhammad Fauzi, "Analisis Peramalan Penjualan Rokok SKT (Sigaret Kretek Tangan) Pada PT. Djitoe Indonesian Tobacco Coy Surakarta," p. 71, 2009.
- [14] F. Nur H and E. Widya F, "Manajemen Produksi dan Operasi dalam Perusahaan," Prpgram Studi Agribisnis Fakultas Pertanian Universitas Brawijaya, Malang, 2013.
- [15] J. Heizer and B. render, *Managemen Operasi* Edisi 9 Terjemahan Chriswan Sungkono, Jaarta: Salemba Empat, 2009.
- [16] Y. Edward, "Information Technology (Metode Forecasting)," 21 September 2015. [Online]. Available: <http://yuliusehs.blog.widyatama.ac.id/2015/09/21/information-technology-metode-forecasting/>. [Accessed 2 oktober 2015].
- [17] M. Spyros, W. Steven C and H. Rob J, *Forecasting Methods and Application* 3rd Edition, John Wiley and Sons inc., 1998.
- [18] M. Savira and N. N.K., "Analisis Peramalan Penjualan Obat Generik Berlogo (OGB) pada PT. Indonesia Farma," p. 12, 2014.
- [19] M. F. Fad, "Peramalan Adalah Perhitungan Yang Objektif Dan Dengan Menggunakan Data," 2015. [Online]. Available: <http://www.scribd.com/doc/123304851/Peramalan-Adalah-Perhitungan-Yang-Objektif-Dan-Dengan-Menggunakan-Data#scribd>. [Accessed 3 Oktober 2015].
- [20] T. M. Mitchell, *Machine Learning*, McGraw-Hill Science/Engineering/Math, 1997.
- [21] S. Russel and P. Norvig, *Artificial Intellegence A Modern Approach* 3rd Edition, New Jersey: Pearson Education, Inc., 2010.
- [22] A. R. Barabah, "neural Network," in *Soft Computing Research Group EEPIS-ITS*, Surabaya, 2009.
- [23] D. H, M. Hagan and M. Baele, "Neural Network Toolbox User's Guide," Natick, The Mathworks Inc, 2015.
- [24] M. D.O, "Implementasi Jaringan Saraf Tiruan Backpropagation dalam Memprediksi Kurs Valuta Asing," *Fakultas Teknologi Industri Universitas Gundarma.*, 2010.

Terima Kasih ☺