



## PERAMALAN PENJUALAN SEMEN MENGGUNAKAN *BACKPROPAGATION NEURAL NETWORK* DAN *RECURRENT NEURAL NETWORK*

Aisyah Fany Achmalia<sup>✉</sup>, Walid, Sugiman

Jurusan Matematika, FMIPA, Universitas Negeri Semarang, Indonesia  
Gedung D7 Lt. 1, Kampus Sekaran Gunungpati, Semarang 50229

### Info Artikel

Sejarah Artikel:  
Diterima April 2019  
Disetujui Mei 2019  
Dipublikasikan November 2019

*Keywords:*  
*backpropagation neural network*  
*forecasting*  
*recurrent neural network*  
*sales*

### Abstrak

*Backpropagation Neural Network (BPNN)* adalah *Neural Network (NN)* yang tidak memiliki loop, sedangkan *Recurrent Neural Network (RNN)* adalah NN yang memiliki minimal satu *feedback loop*. Dalam penelitian ini dilakukan peramalan penjualan semen di PT Semen Indonesia (Persero) Tbk dengan menggunakan BPNN dan RNN tipe Elman. Tujuan penelitian ini adalah untuk memperoleh pemodelan BPNN dan RNN tipe Elman untuk peramalan penjualan semen, serta hasil peramalan menggunakan model terbaik. Hasil penelitian menunjukkan model BPNN terbaik adalah BPNN (9-5-1) dengan algoritma pelatihan *Levenberg-Marquardt* dengan inisialisasi  $\mu$  yang digunakan adalah 0,02 dan fungsi aktivasi yang digunakan adalah *logsig*, sedangkan model RNN tipe Elman terbaik adalah RNN tipe Elman (9-5-1) dengan algoritma pelatihan *gradient descent* dengan momentum dan *adaptive learning rate* dengan momentum yang digunakan adalah 0,2, learning rate yang digunakan adalah 0,2, dan fungsi aktivasi yang digunakan adalah *logsig*. Model terbaik untuk peramalan penjualan semen di PT Semen Indonesia (Persero) Tbk adalah BPNN (9-5-1).

### Abstract

*Backpropagation Neural Network (BPNN)* is a *Neural Network (NN)* that does not have a loop, while *Recurrent Neural Network (RNN)* is a NN has at least one *feedback loop*. In this research, cement sales forecasting was carried out at PT Semen Indonesia (Persero) Tbk by using BPNN and Elman type RNN. The purpose of this research was to obtain BPNN and Elman type RNN modeling for cement sales forecasting, as well as forecasting results using the best models. The results show the best BPNN model is the BPNN (9-5-1) with the *Levenberg-Marquardt* training algorithm with  $\mu$  initialization used is 0,02 and the activation function used is *logsig*, while the best Elman type RNN model is the Elman type RNN (9-5-1) with *gradient descent* with momentum and *adaptive learning rate* training algorithm with the momentum used is 0,2, the learning rate used is 0,2, and the activation function used is *logsig*. The best model for cement sales forecasting at PT Semen Indonesia (Persero) Tbk is the BPNN (9-5-1).

### How to Cite

Achmalia A. F., Walid, & Sugiman. (2019). Peramalan Penjualan Semen Menggunakan Backpropagation Neural Network dan Recurrent Neural Network. *UNNES Journal of Mathematics* 8(1): 92-106

## PENDAHULUAN

Perkembangan teknologi dari hari ke hari semakin canggih dan berkembang dengan pesat. Perkembangan teknologi saat ini tidak dapat dipisahkan dari kehidupan manusia. Perkembangan pada zaman sekarang ini cenderung untuk mengembangkan teknologi yang cerdas dengan memiliki kemampuan untuk berpikir dan mengambil keputusan layaknya manusia. Kecerdasan teknologi diharapkan mampu membantu berbagai persoalan dalam kehidupan sehari-hari dengan cepat dan akurat.

Banyak kecerdasan buatan yang dapat diterapkan dalam banyak bidang dalam kehidupan. Para ahli mencoba untuk mengadaptasi otak manusia ke dalam sistem komputer sehingga diharapkan di masa yang akan datang kecerdasan buatan tersebut dapat mendekati kerja otak manusia. Penerapan kecerdasan buatan yang sering diaplikasikan dalam berbagai persoalan di kehidupan salah satunya adalah jaringan syaraf tiruan.

Jaringan Syaraf Tiruan (JST) atau yang sering dikenal dengan *Neural Network* (NN) adalah sistem pemrosesan informasi yang memiliki karakteristik mirip dengan jaringan syaraf biologis (Fausett, 1994: 3). NN merupakan salah satu dari sistem informasi yang didesain dengan menirukan kerja otak manusia dalam menyelesaikan suatu masalah dengan melakukan proses belajar melalui perubahan bobot sinapsisnya. NN telah dikembangkan sebagai generalisasi model matematika dari kognisi manusia atau syaraf biologi. NN ditandai dengan pola hubungan antara neuron (arsitektur), algoritma untuk menentukan bobot penghubung (pelatihan, atau belajar, algoritma), dan fungsi aktivasi (Fausett, 1994: 3). NN bermanfaat untuk pengenalan pola, *signal processing*, pengklasifikasian dan peramalan (Siang, 2004: 5).

Setiap perusahaan dituntut untuk merencanakan produksinya seefektif mungkin agar dapat memaksimalkan keuntungan. Salah satu alat untuk membuat perencanaan produksi yang baik adalah dengan melakukan estimasi terhadap pasar potensial yang dapat dikuasai oleh perusahaan. Estimasi penjualan atau peramalan penjualan pada hakekatnya adalah perkiraan yang dapat digunakan sebagai target

penjualan perusahaan di masa mendatang. Menurut Arsyad (1994: 7), peramalan menjadi input bagi proses perencanaan dan pengambilan keputusan. Peramalan menunjukkan perkiraan yang akan terjadi pada suatu keadaan tertentu dan perencanaan menggunakan peramalan tersebut untuk membantu para pengambil keputusan dalam memilih alternatif terbaik jika penjualan yang diramalkan menurun.

PT Semen Indonesia (Persero) Tbk adalah produsen semen terbesar di Indonesia dan memiliki anak perusahaan yaitu PT Semen Gresik, PT Semen Padang, PT Semen Tonasa, dan Thang Long Cement Company yang tergabung dalam Semen Indonesia Group. Saat ini kapasitas terpasang PT Semen Indonesia (Persero) Tbk sebesar 29 juta ton semen per tahun dan menguasai sekitar 42% pangsa pasar domestik (Wikipedia, 2018).

Persaingan bisnis semen di Indonesia semakin kompetitif seiring dengan gencarnya penambahan pabrik baru dan masuknya investor baru ke bisnis ini. Sebagai perusahaan produsen semen terkemuka di Indonesia, PT Semen Indonesia (Persero) Tbk harus selalu berupaya menjadi yang terbaik untuk mempertahankan posisinya dengan terus meningkatkan penjualan produknya seiring dengan ketatnya persaingan bisnis (Portal BUMN, 2013). Berdasarkan laporan Asosiasi Semen Indonesia (ASI) di bulan Januari sampai dengan bulan November 2017 tercatat permintaan semen domestik mencapai 60,55 juta ton atau naik 7,8% dibandingkan periode yang sama tahun 2016 (Kontan, 2017). Saat ini permintaan semen curah mengalami peningkatan. Jika sebelumnya porsi penjualan semen curah nasional hanya 20%, saat ini porsinya sudah mencapai 25% (Portal BUMN, 2018). Ketua Umum ASI Widodo Santoso menyatakan kenaikan permintaan semen nasional bukan hanya terjadi di pasar domestik, tapi permintaan semen juga melonjak di pasar ekspor (Semen Indonesia, 2017). Oleh karena itu, untuk memenuhi permintaan semen yang terus meningkat diperlukan perencanaan dan pengawasan manajemen perusahaan yang baik.

Salah satu keberhasilan suatu perusahaan ditentukan oleh perencanaan dalam manajemennya. Perencanaan dalam manajemen perusahaan harus meliputi disegala

bidang, salah satunya adalah bidang penjualan dengan menyusun rencana penjualan. Rencana penjualan salah satunya berbentuk peramalan penjualan, dengan dilakukannya peramalan penjualan yang akurat dapat meningkatkan penjualan produk dan mendatangkan laba bagi perusahaan.

Peramalan adalah suatu teknik untuk meramalkan keadaan di masa yang akan datang melalui pengujian keadaan di masa lalu. Dasarnya meramalkan sama halnya dengan memprediksi atau memperkirakan suatu hal, kejadian atau peristiwa masa datang yang berdasar data pada masa lalu (time series atau runtun waktu) hingga saat ini. Metode peramalan sangat banyak dan seringkali memerlukan asumsi-asumsi yang harus dipenuhi, namun terdapat juga model yang tidak memerlukan asumsi-asumsi salah satunya adalah NN (Kusumadewi, 2014).

NN adalah model non parametrik yang mempunyai bentuk fungsional yang fleksibel, mengandung beberapa parameter yang tidak dapat ditafsirkan jika dalam model parametrik (Walid *et al.*, 2015). NN muncul sebagai model kuantitatif yang penting untuk peramalan bisnis. NN merupakan algoritma yang serba guna untuk aplikasi peramalan dalam hal itu tidak hanya dapat untuk menemukan non linier dalam suatu masalah, tetapi NN juga dapat memodelkan proses linier (Zhang, 2004: 2). NN bekerja dengan mensimulasikan sejumlah besar unit pemrosesan sederhana yang saling berhubungan yang menyerupai versi abstrak dari neuron. Unit pemrosesan disusun berlapis-lapis. Biasanya ada tiga bagian dalam NN, yaitu lapisan *input* dengan neuron yang mewakili bidang *input*, satu atau lebih lapisan tersembunyi, dan lapisan *output* dengan satu atau lebih neuron yang mewakili bidang *output*. Neuron terhubung dengan berbagai bobot. Data input disampaikan ke lapisan pertama, dan nilai-nilai disebarkan dari satu neuron ke neuron lain pada lapisan berikutnya. Akhirnya, hasilnya dikirimkan dari lapisan *output* (Bahadir, 2016).

Berdasarkan kemampuan belajar yang dimilikinya, maka NN dapat dilatih untuk mempelajari dan menganalisa pola data masa lalu dan berusaha mencari suatu formula atau fungsi yang akan menghubungkan pola data

masa lalu dengan *output* yang diinginkan pada saat ini (Salman & Prasetyo, 2010). Salah satu kelebihan dari model NN dalam algoritma peramalan yaitu dapat digunakan untuk meramalkan data *time series* non linier (Hikmah, 2017).

Menurut Valipour *et al.* (2013), dengan meningkatkan *target error* pada NN memungkinkan untuk mencegah variasi pelatihan yang parah dan tidak menguntungkan dan pada gantinya membatalkan pelatihan di dalam jaringan. Lebih banyak neuron di lapisan tersembunyi menyebabkan lebih banyak derajat kebebasan dalam jaringan. Semakin banyak variabel dioptimalkan, waktu perpanjangan pelatihan, dan matriks bobot dan vektor bias menjadi lebih tinggi. Selain itu, jumlah neuron yang lebih tinggi menghasilkan kemungkinan peningkatan penemuan jawaban dan banyak kesempatan untuk mencegah jatuh di minimum lokal.

Menurut Suhada (2009), peramalan dengan menggunakan pendekatan NN memberikan nilai MSE yang sangat kecil mendekati nol. Hal ini berarti bahwa NN memiliki akurasi yang sangat tinggi dalam melakukan peramalan terhadap suatu model sistem. Menurut Walid *et al.* (2015), peramalan menggunakan NN menghasilkan hasil yang jauh lebih baik dibandingkan dengan model ARIMA (*Autoregressive Integrated Moving Average*). Menurut Kohzadi *et al.* (1996), peramalan dengan NN jauh lebih akurat dibandingkan dengan model tradisional ARIMA. Alasan mengapa model NN lebih baik daripada model ARIMA karena data mengandung perilaku non linier yang tidak dapat sepenuhnya ditangkap oleh model ARIMA linier. Namun, jika dibandingkan dengan algoritma peramalan tradisional seperti model ARIMA atau model regresi, ada banyak faktor pemodelan yang perlu dipertimbangkan dalam NN (Zhang & Hu, 1998).

NN dibagi menjadi dua kelompok, yaitu *Feedforward Neural Network* (FFNN) dan *Recurrent/feedback Neural Network* (RNN) (Puspitaningrum, 2006: 10). FFNN dapat juga disebut dengan *Backpropagation Neural Network* (BPNN) (Yang *et al.*, 2013). Menurut Puspitaningrum (2006: 10), FFNN adalah NN yang bergerak maju dan tidak memiliki loop

dimana aliran sinyalnya dari neuron input ke neuron output, sedangkan RNN adalah NN berulang atau umpan balik yang dicirikan dengan adanya loop-loop koneksi balik dimana jalur sinyal loop tertutup dari neuron kembali ke dirinya sendiri.

BPNN pada dasarnya adalah fungsi pemetaan dari neuron input ke neuron output tanpa mengetahui korelasi antar data. Setelah mempelajari trend data dari data historis, BPNN dapat digunakan secara efektif untuk meramalkan data baru (Ren *et al.*, 2014). BPNN adalah model NN yang diakui secara kritis karena kapasitas pemodelan non parametrik dan non liniernya, kemampuan beradaptasi yang kuat, dan kemampuan komputasi paralel. Standar BPNN terdiri dari lapisan *input*, satu atau lebih lapisan tersembunyi, dan lapisan *output*. Secara umum, BPNN dengan satu lapisan tersembunyi dapat menghasilkan akurasi yang diinginkan untuk aplikasi peramalan runtun waktu (Wang *et al.*, 2018). BPNN adalah suatu kelas dari FFNN dengan aturan pembelajaran terawasi. Proses pembelajaran terawasi adalah proses membandingkan setiap perkiraan jaringan dengan jawaban benar yang diketahui dan menyesuaikan berat berdasarkan *error* perkiraan yang dihasilkan untuk meminimalkan fungsi error (Kaastra & Boyd, 1996). Pendekatan BPNN memberikan alternatif kompetitif untuk prosedur yang ada untuk pembelajaran serta peramalan data independen (Chakraborty *et al.*, 1992). Perkembangan terbaru dalam belajar NN menunjukkan bahwa FFNN adalah struktur pemetaan non linier yang dapat mendekati fungsi arbitrer apapun. Oleh karena itu, model non linier seperti itu lebih unggul dari model tradisional ARIMA untuk peramalan time series (Kohzadi *et al.*, 1996).

RNN memiliki karakteristik yang unik, yaitu arsitekturnya memiliki minimal satu *feedback loop*, sehingga dapat menyimpan data dalam struktur jaringannya dan performansi dari RNN dalam melakukan prediksi bergantung pada bobot dan arsitekturnya (Hardianto *et al.*, 2011). Keunikan RNN yang lain adalah adanya koneksi umpan balik yang membawa informasi gangguan (*noise*) pada saat input sebelumnya yang akan diakomodasikan bagi input berikutnya (Salman & Prasetio, 2010).

Penelitian ini menggunakan RNN tipe Elman. Standar RNN tipe Elman terdiri dari empat lapisan, yaitu lapisan *input*, lapisan konteks, lapisan tersembunyi, dan lapisan *output*. Lapisan konteks membuat salinan dari lapisan tersembunyi yang dihasilkan pada langkah waktu sebelumnya, menyimpan catatan operasi jaringan sebelumnya. Jaringan ini memiliki koneksi paralel yang sangat besar, tidak hanya antara lapisan tersembunyi dan *output* tetapi juga antara lapisan tersembunyi dan *input* dan neuron konteks. Koneksi-diri membuat jaringan menjadi peka terhadap historis *input*, sehingga memungkinkannya untuk melakukan pemetaan input dan pola target non linier yang bervariasi waktu (Wang *et al.*, 2018). Tidak seperti pada BPNN, pada RNN tipe Elman fungsi aktivasi dapat berupa sembarang fungsi, baik yang kontinu maupun yang diskontinu (Kusumadewi, 2004). RNN tipe Elman dapat menjelaskan efek berurutan dari model AR (*Autoregressive*) dan MA (*Moving Average*) secara bersamaan untuk meramalkan beberapa runtun waktu musiman dan membandingkan akurasi prakiraan dengan menggunakan model ARIMA musiman (Walid *et al.*, 2015).

Penelitian yang sudah dilakukan dengan menggunakan algoritma BPNN maupun algoritma RNN untuk menyelesaikan masalah peramalan antara lain penelitian yang dilakukan oleh Salman & Prasetio (2010) yang menggunakan RNN dengan algoritma pelatihan *gradient descent adaptive learning rate* untuk pendugaan curah hujan berdasarkan peubah ENSO (*El-Nin Southern Oscillation*), penelitian yang dilakukan oleh Pakaja *et al.* (2012) yang menggunakan BPNN untuk meramalkan penjualan mobil, penelitian yang dilakukan oleh Rizal & Hartati (2017) untuk memprediksi kunjungan wisatawan di pulau Lombok dengan menggunakan RNN *Extended Kalman Filter*, dan Udin *et al.* (2017) yang menggunakan BPNN dan RNN dengan algoritma pelatihan *levenberg marquardt neural network* untuk meramalkan kapasitas baterai *lead acid* pada mobil listrik.

Berdasarkan penelitian-penelitian yang telah dilakukan maka perlu adanya pengembangan metode pada NN yang dapat memberikan hasil peramalan yang lebih akurat. Oleh karena itu, akan dilakukan penelitian

dengan membandingkan BPNN dengan RNN tipe Elman untuk menghitung peramalan penjualan semen di PT Semen Indonesia (Persero) Tbk.

Rumusan masalah dalam penelitian ini adalah 1) Bagaimana pemodelan *Backpropagation Neural Network* (BPNN) untuk peramalan penjualan semen di PT Semen Indonesia (Persero) Tbk, 2) Bagaimana pemodelan *Recurrent Neural Network* (RNN) untuk peramalan penjualan semen di PT Semen Indonesia (Persero) Tbk, 3) Berapakah hasil peramalan penjualan semen di PT Semen Indonesia (Persero) Tbk untuk sembilan periode berikutnya berdasarkan pada model terbaik.

Tujuan dari penelitian ini adalah 1) mengetahui pemodelan *Backpropagation Neural Network* (BPNN) untuk peramalan penjualan semen di PT Semen Indonesia (Persero) Tbk, 2) mengetahui pemodelan *Recurrent Neural Network* (RNN) untuk peramalan penjualan semen di PT Semen Indonesia (Persero) Tbk, 3) mengetahui hasil peramalan penjualan semen di PT Semen Indonesia (Persero) Tbk untuk sembilan periode berikutnya berdasarkan model terbaik.

## METODE

Metode yang digunakan dalam penelitian ini adalah metode studi pustaka. Studi pustaka dilakukan dengan mengumpulkan sumber pustaka yang berupa buku, jurnal, skripsi, dan literatur lainnya. Data yang digunakan adalah data *volume* penjualan semen di PT Semen Indonesia (Persero) Tbk mulai Bulan Januari sampai dengan Bulan Desember 2018 yang merupakan data sekunder dari publikasi PT Semen Indonesia (Persero) Tbk.

Perangkat yang digunakan untuk peramalan penjualan semen di PT Semen Indonesia (Persero) Tbk menggunakan BPNN dan RNN tipe Elman dikembangkan pada *hardware* dengan spesifikasi yang terdiri dari: (1) Komputer ASUS *series* K43SA, (2) *Processor* Intel(R) Core(TM) i5-2430M CPU @ 2.40GHz, (3) RAM 4,00 GB, (4) HDD 640 GB. *Software* terdiri dari: (1) OS *Windows* 7 Ultimate, (2) 64-bit *Operating System*, (3) Matlab R2018a.


Peramalan penjualan semen menggunakan algoritma BPNN dan RNN tipe Elman dibantu dengan software Matlab

R2018a. Langkah-langkah pemecahan masalah dalam penelitian ini sebagai berikut.


1. Mengidentifikasi dan merumuskan masalah yang akan dikaji.
2. Mengumpulkan studi pustaka yang berkaitan dengan permasalahan.
3. Melakukan pengumpulan data *volume* penjualan semen di PT Semen Indonesia (Persero) Tbk di *website* resmi PT Semen Indonesia (Persero) Tbk di [www.semenindonesia.com](http://www.semenindonesia.com).
4. Melakukan penentuan *input* dan target jaringan dengan melihat lag-lag yang signifikan pada plot PACF.
5. Membagi data menjadi dua bagian, yaitu data latih dan data uji.
6. Menormalisasikan data *input* dan data target.
7. Membangun jaringan BPNN dan RNN tipe Elman.
8. Melakukan pelatihan dan pengujian data.
9. Mendenormalisasi data agar data menjadi seperti semula.
10. Menentukan model terbaik berdasarkan MSE dan MAPE tahap pengujian terkecil pada masing-masing model pada BPNN dan RNN tipe Elman.
11. Melakukan uji kesesuaian model dengan melihat plot *regression* pada tahap pelatihan masing-masing model pada BPNN dan RNN tipe Elman.
12. Melakukan peramalan untuk beberapa periode berikutnya dengan model terbaik pada BPNN dan RNN tipe Elman.
13. Menghitung akurasi dari hasil peramalan masing-masing model pada BPNN dan RNN tipe Elman.
14. Membuat kesimpulan.

## HASIL DAN PEMBAHASAN

Penerapan algoritma *Backpropagation Neural Network* (BPNN) dan *Recurrent Neural Network* (RNN) tipe Elman untuk peramalan penjualan semen diterapkan pada data *volume* penjualan semen di PT Semen Indonesia (Persero) Tbk sebanyak 147 data yaitu mulai Bulan Januari 2006 sampai dengan Bulan Maret 2018. Pola data penjualan semen di PT Semen Indonesia (Persero) Tbk ditunjukkan pada Gambar 1.



Gambar 1. Plot Data Penjualan Semen Mulai dari Bulan Januari 2006 sampai dengan Bulan Maret 2018



Gambar 2. Plot PACF Data Penjualan Semen Periode Bulanan Mulai dari Bulan Januari 2006 sampai dengan Bulan Maret 2018

Gambar 2 menunjukkan plot PACF untuk data penjualan semen. Berdasarkan plot PACF diperoleh lag-lag yang signifikan, yaitu lag 1, lag 2, lag 5, lag 9, lag 10, lag 11, lag 12, lag 13, dan lag 20.

#### Membangun Jaringan BPNN

Penentuan *input* dan target jaringan dalam penelitian ini dengan melihat lag-lag yang signifikan pada plot PACF, Plot PACF pada Gambar 2 menunjukkan lag-lag yang

signifikan, yaitu lag 1, lag 2, lag 5, lag 9, lag 10, lag 11, lag 12, lag 13, dan lag 20, sehingga jaringan yang akan dibangun memiliki *input* sebanyak 9 variabel, yaitu  $x_{t-1}$ ,  $x_{t-2}$ ,  $x_{t-5}$ ,  $x_{t-9}$ ,  $x_{t-10}$ ,  $x_{t-11}$ ,  $x_{t-12}$ ,  $x_{t-13}$ ,  $x_{t-20}$  dan target  $x_t$ . Karena input data yang digunakan adalah data  $x_{t-1}$ ,  $x_{t-2}$ ,  $x_{t-5}$ ,  $x_{t-9}$ ,  $x_{t-10}$ ,  $x_{t-11}$ ,  $x_{t-12}$ ,  $x_{t-13}$ ,  $x_{t-20}$  maka data ke-1 sampai dengan data ke-20 tidak dapat digunakan, sehingga selanjutnya penelitian menggunakan data ke-21 sampai dengan data ke-147, yaitu sebanyak 127 data.

Berdasarkan *trial and error* diperoleh bahwa komposisi pembagian data yang digunakan untuk membangun jaringan BPNN, yaitu 80% untuk data latih dan 20% untuk data uji, sehingga dari 127 data terdapat 102 data untuk data latih dan 25 data untuk data uji. Setelah pembagian data dilakukan, selanjutnya dilakukan normalisasi data pada data *input* dan data *target* dengan bantuan *software* Matlab R2018a. Setelah data dinormalisasi, dilakukan perancangan model untuk mendapatkan model jaringan terbaik.

Perintah untuk membangun jaringan BPNN untuk peramalan penjualan semen, yaitu:

```
net = newff(minmax(pn), [n 1],
{'tansig' 'purelin'}, 'traingdx');
```

Perintah `newff` digunakan untuk membangun jaringan BPNN dengan  $n$  neuron pada satu lapisan tersembunyi dan satu neuron pada satu lapisan *output*. Perintah {'tansig' 'purelin'} menunjukkan fungsi aktivasi yang digunakan dengan `tansig` pada lapisan tersembunyi dan `purelin` pada lapisan *output*. Perintah `traingdx` menunjukkan algoritma pelatihan yang digunakan.

Langkah-langkah pembentukan model terbaik untuk membangun jaringan BPNN peramalan penjualan semen sebagai berikut.

1. Penentuan jaringan yang optimum  
Lapisan tersembunyi yang digunakan ada satu lapisan tersembunyi dan untuk neuron tersembunyi diperoleh berdasarkan *trial and error* pada jumlah neuron tersembunyi sebesar 5 neuron, 10 neuron, 15 neuron, 20 neuron, dan 25 neuron. Fungsi aktivasi yang digunakan pada lapisan tersembunyi dilakukan *trial and error* pada dua fungsi aktivasi, yaitu fungsi sigmoid biner yang pada Matlab dikenal dengan nama `logsig` dan fungsi sigmoid bipolar yang pada Matlab dikenal dengan nama `tansig`, sedangkan pada lapisan *output* digunakan fungsi linear atau identitas yang pada Matlab dikenal dengan nama `purelin`.
2. Penentuan algoritma pelatihan  
Algoritma pelatihan yang digunakan untuk membangun jaringan BPNN dilakukan *trial and error* pada dua algoritma pelatihan, yaitu *gradient descent* dengan momentum

dan *adaptive learning rate* yang pada Matlab dikenal dengan nama `traingdx` dan *Levenberg-Marquardt* yang pada Matlab dikenal dengan nama `trainlm`.

3. Penentuan parameter pelatihan  
Parameter yang dipilih berdasarkan pada algoritma pelatihan yang digunakan. Parameter yang digunakan pada algoritma pelatihan *gradient descent* dengan momentum dan *adaptive learning rate* dapat dilihat pada Tabel 1, sedangkan parameter yang digunakan pada algoritma pelatihan *Levenberg-Marquardt* dapat dilihat pada Tabel 2.

Tabel 1. Parameter Pelatihan untuk Algoritma Pelatihan *Gradient Descent* dengan Momentum dan *Adaptive Learning Rate*

Maksimum <i>epoch</i>	: 5000
Target <i>error</i>	: 0,001
<i>Learning rate</i> (LR)	: 0,01, 0,02, 0,03, 0,1 0,2, 0,3
Momentum	: 0,1, 0,2, 0,8, 0,9
<i>Epoch show</i>	: 500

Tabel 2. Parameter Pelatihan untuk Algoritma Pelatihan *Levenberg-Marquardt*

Maksimum <i>epoch</i>	: 5000
Target <i>error</i>	: 0,001
Inisialisasi $\mu$	: 0,001, 0,002, 0,003, 0,004, 0,005, 0,006, 0,007, 0,01, 0,02, 0,03, 0,04, 0,05, 0,06, 0,07, 0,1, 0,2, 0,3, 0,4, 0,5, 0,6, 0,7, 1, 2, 3
<i>Epoch show</i>	: 500

Setelah proses pelatihan selesai dilakukan, maka hasil *output* jaringan yang ternormalisasi dikembalikan lagi seperti semula yang disebut dengan denormalisasi data. Setelah dilakukan pelatihan jaringan akan terbentuk berbagai macam model jaringan yang telah dihasilkan melalui tahap pembentukan model. Model terbaik terbentuk berdasarkan *trial and error* terhadap beberapa macam arsitektur jaringan pada BPNN. Model terbaik adalah model dengan MSE dan MAPE pengujian terkecil dengan jaringan paling sederhana.

Berdasarkan hasil pelatihan jaringan pada Tabel 3 diperoleh bahwa model BPNN terbaik dengan algoritma pelatihan *gradient descent* dengan momentum dan *adaptive learning rate* pada arsitektur jaringan 9-10-1 dengan momentum = 0,8 dan LR = 0,1 pada fungsi aktivasi tansig. Model BPNN (9-10-1) memperoleh hasil pada *epoch* ke 5000 yang memberikan nilai MSE dan MAPE pengujian masing-masing sebesar 3,6069e+10 dan 6,7670%. Iterasi berhenti pada *epoch* ke 5000 meskipun target *error* yang diinginkan (Goal = 0,001) belum tercapai. Model ini pada *epoch* ke 5000 telah mencapai konvergen dengan *performance* = 0,00784.

Berdasarkan hasil pelatihan jaringan pada Tabel 4 diperoleh bahwa model BPNN terbaik dengan algoritma pelatihan *Levenberg-Marquardt* pada arsitektur jaringan 9-5-1 dengan Mu = 0,02 pada fungsi aktivasi logsig. Model BPNN (9-5-1) memperoleh hasil pada *epoch* ke 5000 yang memberikan nilai MSE dan MAPE pengujian masing-masing sebesar 3,4239e+10 dan 6,7659%. Iterasi berhenti pada *epoch* ke 5000 meskipun target *error* yang diinginkan (Goal = 0,001) belum tercapai. Model ini pada *epoch* ke 5000 telah mencapai konvergen dengan *performance* = 0,0262.

Berdasarkan hasil pelatihan BPNN dengan algoritma pelatihan *gradient descent* dengan momentum dan *adaptive learning rate* dan algoritma pelatihan *Levenberg-Marquardt* diperoleh MSE dan MAPE pengujian terkecil

dengan nilai MSE sebesar 3,4239e+10 dan MAPE sebesar 6,7659% dihasilkan pada algoritma pelatihan *Levenberg-Marquardt* dengan arsitektur jaringan 9-5-1 dengan inisialisasi Mu yang digunakan adalah 0,02 dan fungsi aktivasi yang digunakan adalah logsig. Selanjutnya, melakukan uji kesesuaian model pada model terbaik. Uji kesesuaian model dilakukan untuk melihat apakah model terbaik yang telah diperoleh layak atau tidak untuk digunakan sebagai model peramalan. Pengujian ini dilihat dari plot *regression* pada data latih.

Berdasarkan hasil pelatihan BPNN diperoleh model jaringan terbaik pada arsitektur jaringan 9-5-1 dengan algoritma pelatihan *Levenberg-Marquardt* dengan inisialisasi Mu yang digunakan adalah 0,02 dan fungsi aktivasi yang digunakan adalah logsig. Oleh karena itu, model yang akan digunakan untuk peramalan penjualan semen pada BPNN adalah model dengan arsitektur jaringan 9-5-1 yang terdiri dari 9 neuron pada lapisan *input*, 5 neuron pada lapisan tersembunyi, dan 1 neuron pada lapisan *output*. Uji kesesuaian model BPNN dengan arsitektur jaringan 9-5-1 dapat dilihat dari plot *regression* pada Gambar 3.


Tabel 3. Hasil Pelatihan BPNN dengan Algoritma Pelatihan *Gradient Descent* dengan Momentum dan *Adaptive Learning Rate* dengan Momentum = 0,8 dan LR = 0,1

Arsitektur Jaringan	$f(x)$	Epoch	Perf	Pelatihan			Pengujian		
				MSE	MAPE (%)	R	MSE	MAPE (%)	R
9-10-1	Tansig	5000	0,007848	1,1271e+09	1,4621	0,99603	3,6069e+10	6,7670	0,86422

Tabel 4. Hasil Pelatihan BPNN dengan Algoritma Pelatihan *Levenberg-Marquardt* dengan Mu = 0,02

Arsitektur Jaringan	$f(x)$	Epoch	Perf	Pelatihan			Pengujian		
				MSE	MAPE (%)	R	MSE	MAPE (%)	R
9-5-1	Logsig	5000	0,0262	3,7663e+09	2,4701	0,98668	3,4239e+10	6,7659	0,8744





Gambar 3. Plot *Regression* BPNN pada Arsitektur Jaringan 9-5-1

Gambar 3 menunjukkan bahwa titik-titik mendekati garis diagonalnya dan koefisien korelasi bernilai 0,98668 (mendekati 1) menunjukkan hasil yang baik untuk kecocokan *output* jaringan dengan target, sehingga dapat disimpulkan bahwa model BPNN pada arsitektur 9-5-1 dapat digunakan untuk meramalkan penjualan semen.

### Membangun Jaringan RNN

Plot PACF pada Gambar 2 menunjukkan lag-lag yang signifikan, yaitu lag 1, lag 2, lag 5, lag 9, lag 10, lag 11, lag 12, lag 13, dan lag 20, sehingga jaringan yang akan dibangun memiliki *input* sebanyak 9 variabel, yaitu  $x_{t-1}$ ,  $x_{t-2}$ ,  $x_{t-5}$ ,  $x_{t-9}$ ,  $x_{t-10}$ ,  $x_{t-11}$ ,  $x_{t-12}$ ,  $x_{t-13}$ ,  $x_{t-20}$  dan target  $x_t$ . Karena input data yang digunakan adalah data  $x_{t-1}$ ,  $x_{t-2}$ ,  $x_{t-5}$ ,  $x_{t-9}$ ,  $x_{t-10}$ ,  $x_{t-11}$ ,  $x_{t-12}$ ,  $x_{t-13}$ ,  $x_{t-20}$  maka data ke-1 sampai dengan data ke-20 tidak dapat digunakan, sehingga selanjutnya penelitian menggunakan data ke-21 sampai dengan data ke-147, yaitu sebanyak 127 data.

Berdasarkan *trial and error* diperoleh bahwa komposisi pembagian data yang digunakan untuk membangun jaringan RNN tipe Elman, yaitu 80% untuk data latih dan 20% untuk data uji, sehingga dari 127 data terdapat 102 data untuk data latih dan 25 data untuk data uji. Setelah pembagian data dilakukan, selanjutnya dilakukan normalisasi data pada data *input* dan data target dengan bantuan *software* Matlab R2018a. Setelah data

dinormalisasi, dilakukan perancangan model untuk mendapatkan model jaringan terbaik.

Perintah untuk membangun jaringan RNN tipe Elman untuk peramalan penjualan semen, yaitu:

```
net = newelm(minmax(pn), [n 1],
{'tansig' 'purelin'}, 'traingdx');
```

Perintah `newelm` digunakan untuk membangun jaringan RNN tipe Elman dengan  $n$  neuron pada lapisan tersembunyi dan satu neuron pada lapisan *output*. Perintah `{'tansig' 'purelin'}` menunjukkan fungsi aktivasi yang digunakan dengan `tansig` pada lapisan tersembunyi dan `purelin` pada lapisan *output*. Perintah `traingdx` menunjukkan algoritma pelatihan yang digunakan.

Langkah-langkah pembentukan model terbaik untuk membangun jaringan RNN tipe Elman peramalan penjualan semen sebagai berikut.

1. Penentuan jaringan yang optimum  
Lapisan tersembunyi yang digunakan ada satu lapisan tersembunyi dan untuk neuron tersembunyi diperoleh berdasarkan *trial and error* pada jumlah neuron tersembunyi sebesar 5 neuron, 10 neuron, 15 neuron, 20 neuron, dan 25 neuron. Fungsi aktivasi yang digunakan pada lapisan tersembunyi dilakukan *trial and error* pada dua fungsi aktivasi, yaitu fungsi sigmoid biner yang pada Matlab dikenal dengan nama `logsig` dan fungsi sigmoid bipolar yang pada Matlab dikenal dengan nama `tansig`, sedangkan pada lapisan *output* digunakan fungsi linear atau identitas yang pada Matlab dikenal dengan nama `purelin`.
2. Penentuan algoritma pelatihan  
Algoritma pelatihan yang digunakan untuk membangun jaringan RNN tipe Elman dilakukan *trial and error* pada dua algoritma pelatihan, yaitu *gradient descent* dengan momentum dan *adaptive learning rate* yang pada Matlab dikenal dengan nama `traingdx` dan *Levenberg-Marquardt* yang pada Matlab dikenal dengan nama `trainlm`.
3. Penentuan parameter pelatihan  
Parameter yang dipilih berdasarkan pada algoritma pelatihan yang digunakan.

Parameter yang digunakan pada algoritma pelatihan *gradient descent* dengan momentum dan *adaptive learning rate* dapat dilihat pada Tabel 1, sedangkan parameter yang digunakan pada algoritma pelatihan *Levenberg-Marquardt* dapat dilihat pada Tabel 2.

Setelah proses pelatihan selesai dilakukan, maka hasil *output* jaringan yang ternormalisasi dikembalikan lagi seperti semula yang disebut dengan denormalisasi data. Setelah dilakukan pelatihan jaringan akan terbentuk berbagai macam model jaringan yang telah dihasilkan melalui tahap pembentukan model. Model terbaik terbentuk berdasarkan *trial and error* terhadap beberapa macam arsitektur jaringan pada RNN tipe Elman. Model terbaik adalah model dengan MSE dan MAPE pengujian terkecil dengan jaringan paling sederhana.

Berdasarkan hasil pelatihan jaringan pada Tabel 5 diperoleh bahwa model RNN tipe Elman terbaik dengan algoritma pelatihan *gradient descent* dengan momentum dan *adaptive learning rate* pada arsitektur jaringan 9-5-1 dengan momentum = 0,2 dan LR = 0,2 pada fungsi aktivasi *logsig*. Model RNN tipe Elman (9-5-1) memperoleh hasil pada *epoch* ke 5000 yang memberikan nilai MSE dan MAPE pengujian masing-masing sebesar 3,3772e+10 dan 6,3738%. Iterasi berhenti pada *epoch* ke 5000 meskipun target *error* yang diinginkan (Goal = 0,001) belum tercapai. Model ini pada *epoch* ke 5000 telah mencapai konvergen dengan *performance* = 0,0562.

Berdasarkan hasil pelatihan jaringan pada Tabel 6 diperoleh bahwa model RNN tipe Elman terbaik dengan algoritma pelatihan *Levenberg-Marquardt* pada arsitektur jaringan 9-5-1 dengan  $\mu = 0,03$  pada fungsi aktivasi *tansig*. Model RNN tipe Elman (9-5-1) memperoleh hasil pada *epoch* ke 779 yang memberikan nilai MSE dan MAPE pengujian

masing-masing sebesar 4,4097e+10 dan 7,4589%. Iterasi berhenti pada *epoch* ke 779 (*Epoch* = 5000) dan goal ke 0,0220 meskipun target *error* yang diinginkan (Goal = 0,001) belum tercapai. Model ini pada *epoch* ke 779 telah mencapai konvergen dengan *performance* = 0,0220.

Berdasarkan hasil pelatihan RNN tipe Elman dengan algoritma pelatihan *gradient descent* dengan momentum dan *adaptive learning rate* dan algoritma pelatihan *Levenberg-Marquardt* diperoleh MSE dan MAPE pengujian terkecil dengan nilai MSE sebesar 3,3772e+10 dan MAPE sebesar 6,3738% dihasilkan pada algoritma pelatihan *gradient descent* dengan momentum dan *adaptive learning rate* dengan arsitektur jaringan 9-5-1 dengan momentum yang digunakan adalah 0,2, *learning rate* yang digunakan adalah 0,2, dan fungsi aktivasi yang digunakan adalah *logsig*. Selanjutnya, melakukan uji kesesuaian model pada model terbaik. Uji kesesuaian model dilakukan untuk melihat apakah model terbaik yang telah diperoleh layak atau tidak untuk digunakan sebagai model peramalan. Pengujian ini dilihat dari plot *regression* pada data latih.


Berdasarkan hasil pelatihan RNN tipe Elman diperoleh model jaringan terbaik pada arsitektur jaringan 9-5-1 dengan algoritma pelatihan *gradient descent* dengan momentum dan *adaptive learning rate* dengan momentum yang digunakan adalah 0,2, *learning rate* yang digunakan adalah 0,2, dan fungsi aktivasi yang digunakan adalah *logsig*. Oleh karena itu, model yang akan digunakan untuk peramalan penjualan semen pada RNN tipe Elman adalah model dengan arsitektur jaringan 9-5-1 yang terdiri dari 9 neuron pada lapisan *input*, 5 neuron pada lapisan tersembunyi, dan 1 neuron pada lapisan *output*. Uji kesesuaian model RNN tipe Elman dengan arsitektur jaringan 9-5-1 dapat dilihat dari plot *regression* pada Gambar 4.

Tabel 5. Hasil Pelatihan RNN Tipe Elman dengan Algoritma Pelatihan *Gradient Descent* dengan Momentum dan *Adaptive Learning Rate* dengan Momentum = 0,2 dan LR = 0,2

Arsitektur Jaringan	$f(x)$	<i>Epoch</i>	Perf	Pelatihan			Pengujian		
				MSE	MAPE (%)	R	MSE	MAPE (%)	R
9-5-1	Logsig	5000	0,0562	8,0702e+09	1,4621	0,9712	3,3772e+10	6,3738	0,8504

Tabel 6. Hasil Pelatihan RNN Tipe Elman dengan Algoritma Pelatihan *Levenberg-Marquardt* dengan  $\mu = 0,03$

Arsitektur Jaringan	$f(x)$	Epoch	Perf	Pelatihan			Pengujian		
				MSE	MAPE (%)	R	MSE	MAPE (%)	R
9-5-1	Tansig	779	0,0220	3,1620e+09	2,4222	0,98883	4,4097e+10	7,4589	0,83382



Gambar 4. Plot *Regression* RNN Tipe Elman pada Arsitektur Jaringan 9-5-1

Gambar 4 menunjukkan bahwa titik-titik mendekati garis diagonalnya dan koefisien korelasi bernilai 0,97123 (mendekati 1) menunjukkan hasil yang baik untuk kecocokan *output* jaringan dengan target, sehingga dapat disimpulkan bahwa model RNN tipe Elman pada arsitektur jaringan 9-5-1 dapat digunakan sebagai model peramalan penjualan semen.

**Model Jaringan BPNN dan RNN untuk Peramalan Penjualan Semen**

Model jaringan BPNN yang digunakan untuk peramalan penjualan semen di PT Semen Indonesia (Persero) Tbk adalah model BPNN (9-5-1) dengan algoritma pelatihan *Levenberg-Marquardt* dengan inisialisasi  $\mu$  yang digunakan adalah 0,02 dan fungsi aktivasi yang digunakan adalah *logsig*. Persamaan model BPNN yang terbentuk dari 9 neuron pada lapisan *input*, 5 neuron pada lapisan tersembunyi, dan 1 neuron pada lapisan *output* sebagai berikut.

$$y_t = \left( \sum_{j=1}^5 w_{kj} \cdot \frac{1}{1 + e^{-(v_{j0} + \sum_{i=1}^9 x_i v_{ji})}} \right) + w_{k0} \tag{1}$$

Model jaringan RNN tipe Elman yang digunakan untuk peramalan penjualan semen di PT Semen Indonesia (Persero) Tbk adalah model RNN tipe Elman (9-5-1) dengan algoritma pelatihan *gradient descent* dengan momentum dan *adaptive learning rate* dengan momentum yang digunakan adalah 0,2, *learning rate* yang digunakan adalah 0,2, dan fungsi aktivasi yang digunakan adalah *logsig*. Persamaan model RNN tipe Elman yang terbentuk dari 9 neuron pada lapisan *input*, 5 neuron pada lapisan tersembunyi, dan 1 neuron pada lapisan *output* sebagai berikut.

$$y_t = \beta_0 + \left( \sum_{j=1}^5 \beta_j \cdot \frac{1}{1 + e^{-(v_{j0} + \sum_{j=1}^5 c_j v_{dj} + \sum_{i=1}^9 x_i v_{ji})}} \right) \tag{2}$$

**Peramalan Penjualan Semen**

Model yang pertama, yaitu model terbaik pada BPNN dan model yang kedua, yaitu model terbaik pada RNN tipe Elman. Keakuratan hasil pengujian dengan kedua model dapat dilihat pada Tabel 7.

Tabel 7. Hasil Pelatihan BPNN dan RNN Tipe Elman dengan Model Terbaik

Model	Pelatihan		Pengujian	
	MSE	MAPE (%)	MSE	MAPE (%)
BPNN (9-5-1)	3,7663e+09	2,4701	3,4239e+10	6,7659
RNN Tipe Elman (9-5-1)	8,0702e+09	4,0344	3,3772e+10	6,3738

Perhitungan peramalan untuk Bulan April 2018 sampai dengan Bulan Desember 2018 menggunakan bantuan *software* Matlab R2018a. Hasil peramalan penjualan semen di

PT Semen Indonesia (Persero) Tbk menggunakan model BPNN (9-5-1) untuk Bulan April 2018 sampai dengan Bulan Desember 2018 dapat dilihat pada Tabel 8, sedangkan hasil peramalan penjualan semen di PT Semen Indonesia (Persero) Tbk menggunakan model RNN tipe Elman (9-5-1) untuk Bulan April 2018 sampai dengan Bulan Desember 2018 dapat dilihat pada Tabel 9.

Tabel 8. Hasil Peramalan Penjualan Semen di PT Semen Indonesia (Persero) Tbk Menggunakan BPNN

Waktu	Hasil Peramalan Penjualan Semen (dalam Ton)
April 2018	2479607
Mei 2018	2344701
Juni 2018	2045132
Juli 2018	2486581
Agustus 2018	2674669
September 2018	2379005
Oktober 2018	2834896
November 2018	2501668
Desember 2018	2918820

Tabel 9. Hasil Peramalan Penjualan Semen di PT Semen Indonesia (Persero) Tbk Menggunakan RNN Tipe Elman

Waktu	Hasil Peramalan Penjualan Semen (dalam Ton)
April 2018	2398034
Mei 2018	1781840
Juni 2018	2008023
Juli 2018	1494894
Agustus 2018	1659707
September 2018	1650800
Oktober 2018	1884715
November 2018	2302057
Desember 2018	2339773

Perbandingan peramalan penjualan semen dilakukan dengan membandingkan data asli pada Bulan April 2018 sampai dengan Bulan Desember 2019 dengan data hasil peramalan pada bulan-bulan tersebut. Perbandingan dilakukan dengan menghitung nilai MAPE dan kemudian diperoleh nilai akurasi. Hasil perbandingan data hasil

peramalan dengan data asli menggunakan BPNN dan RNN tipe Elman dapat dilihat pada Tabel 10.

Tabel 10. Hasil Perbandingan Data Hasil Peramalan dengan Data Asli

Waktu	Data Asli	Hasil Peramalan Penjualan Semen (dalam Ton)	
		BPNN	RNN Tipe Elman
April 2018	2394523	2479607	2398034
Mei 2018	2569981	2344701	1781840
Juni 2018	1571763	2045132	2008023
Juli 2018	2691875	2486581	1494894
Agustus 2018	2903960	2674669	1659707
September 2018	2919475	2379005	1650800
Oktober 2018	3159448	2834896	1884715
November 2018	2843437	2501668	2302057
Desember 2018	2666017	2918820	2339773
MAPE (%)		12,0273	28,9958

Berdasarkan Tabel 10 dapat dilihat bahwa model BPNN (9-5-1) memperoleh MAPE sebesar 12,0273%, sehingga peramalan penjualan semen menggunakan BPNN merupakan peramalan baik dengan akurasi sebesar 87,9727%, sedangkan model RNN tipe Elman (9-5-1) memperoleh MAPE sebesar 28,9958%, sehingga peramalan penjualan semen menggunakan RNN tipe Elman merupakan peramalan cukup baik dengan akurasi sebesar 71,0042%. Berdasarkan hasil peramalan diperoleh bahwa BPNN (9-5-1) mempunyai nilai akurasi yang lebih besar daripada RNN tipe Elman (9-5-1). Hal ini berarti bahwa model BPNN (9-5-1) adalah model terbaik yang dapat digunakan untuk peramalan penjualan semen. Namun, pada hasil pelatihan BPNN dan RNN tipe Elman seperti pada Tabel 7 diperoleh bahwa RNN tipe Elman pada saat pelatihan jaringan memperoleh hasil yang lebih baik daripada BPNN, karena menghasilkan MSE dan MAPE pada tahap pengujian lebih kecil daripada BPNN. Namun, dalam implementasinya untuk peramalan pada penelitian ini, hasil peramalan BPNN (9-5-1) lebih baik daripada RNN tipe Elman (9-5-1). Hal ini sejalan dengan Susanti *et al.* (2013) yang

menyatakan bahwa hasil *error* yang kecil pada saat pelatihan jaringan belum tentu menghasilkan *error* yang kecil pada saat peramalan, sehingga untuk menentukan apakah suatu peramalan baik atau tidak, maka tidak hanya mengandalkan nilai *error* pada pelatihan jaringan saja yang kecil tetapi nilai *error* pada peramalan juga harus kecil. Oleh karena itu, diperoleh bahwa model BPNN (9-5-1) adalah model yang optimal untuk peramalan penjualan semen di PT Semen Indonesia (Persero) Tbk.

## PENUTUP

Berdasarkan hasil pembahasan yang telah dilakukan dapat diambil kesimpulan bahwa model BPNN untuk peramalan penjualan semen di PT Semen Indonesia (Persero) Tbk adalah model BPNN (9-5-1) yang terbangun dari 9 neuron pada lapisan input, 5 neuron pada lapisan tersembunyi, dan 1 neuron pada lapisan *output* dengan algoritma pelatihan *Levenberg-Marquardt* dengan inisialisasi  $\mu$  yang digunakan adalah 0,02 dan fungsi aktivasi yang digunakan adalah *logsig*. Persamaan model BPNN (9-5-1), yaitu

$$y_t = \left( \sum_{j=1}^5 w_{kj} \cdot \frac{1}{1 + e^{-(v_{j0} + \sum_{i=1}^9 x_i v_{ji})}} \right) + w_{k0}$$

Model RNN tipe Elman untuk peramalan penjualan semen di PT Semen Indonesia (Persero) Tbk adalah model RNN tipe Elman (9-5-1) yang terbangun dari 9 neuron pada lapisan input, 5 neuron pada lapisan tersembunyi, dan 1 neuron pada lapisan output dengan algoritma pelatihan *gradient descent* dengan momentum dan *adaptive learning rate* dengan momentum yang digunakan adalah 0,2, *learning rate* yang digunakan adalah 0,2, dan fungsi aktivasi yang digunakan adalah *logsig*. Persamaan model RNN tipe Elman (9-5-1), yaitu

$$y_t = \beta_0 + \left( \sum_{j=1}^5 \beta_j \cdot \frac{1}{1 + e^{-(\gamma_{j0} + \gamma_{dj} + \sum_{i=1}^9 \gamma_{ji} x_i)}} \right)$$

Model terbaik untuk peramalan penjualan semen di PT Semen Indonesia (Persero) Tbk adalah model BPNN (9-5-1) dengan tingkat akurasi sebesar 87,9727% dan merupakan peramalan baik. Hasil peramalan penjualan semen di PT Semen Indonesia (Persero) Tbk menggunakan model BPNN (9-5-

1) dalam skala bulanan untuk sembilan bulan berikutnya untuk Bulan April 2018 adalah 2479607 ton, Bulan Mei 2018 adalah 2344701 ton, Bulan Juni 2018 adalah 2045132 ton, Bulan Juli 2018 adalah 2486581 ton, Bulan Agustus 2018 adalah 2674669 ton, Bulan September 2018 adalah 2379005 ton, Bulan Oktober 2018 adalah 2834896 ton, Bulan November 2018 adalah 2501668 ton, dan Bulan Desember 2018 adalah 2918820 ton.

Adapun saran yang dapat diberikan untuk penelitian selanjutnya, antara lain: (1) untuk menghasilkan proses pelatihan agar berjalan lebih cepat dapat dilakukan penelitian terkait optimasi penentuan bobot awal atau dapat menggunakan metode Nguyen-Widrow, (2) untuk mendapatkan arsitektur model yang lebih baik gunakan lebih banyak variasi pada neuron tersembunyi, lapisan tersembunyi, fungsi aktivasi, algoritma pelatihan, dan parameter-parameter pelatihan yang akan digunakan, (3) Jika pada penelitian ini menggunakan RNN tipe Elman, pada penelitian lain dapat menggunakan RNN tipe *Hopfield*, (4) Jika ingin menggunakan RNN sebagai model peramalan, maka pola data yang digunakan untuk peramalan lebih baik memiliki karakteristik data berulang atau data musiman agar diperoleh hasil peramalan yang memiliki nilai akurasi yang tinggi, dan (5) Untuk perusahaan jika ingin menggunakan penelitian ini dapat melakukan penelitian lebih lanjut dengan menggunakan metode gabungan, seperti penggabungan antara BPNN dengan *fuzzy* atau penggabungan RNN dengan *fuzzy*, penggabungan BPNN dengan algoritma genetika atau penggabungan RNN dengan algoritma genetika, penggabungan BPNN dengan *hybrid* atau penggabungan RNN dengan *hybrid*, dan sebagainya. Hal ini memungkinkan dapat menghasilkan peramalan yang lebih baik nilai akurasinya.

## DAFTAR PUSTAKA

- Arsyad, L. 1994. *Peramalan Bisnis*. Edisi Pertama. Yogyakarta: BPFE.
- Bahadir, E. 2016. Prediction of Prospective Mathematics Teachers' Academic Success in Entering Graduate Education by Using Back-propagation Neural Network. *Journal*

- of Education and Training Studies* 4(5): 113-122.
- Chakraborty, K., Mehrotra, K., Mohan, C. K., & Ranka, S. 1992. Forecasting the Behavior of Multivariate Time Series Using Neural Networks. *Neural Networks* 5: 961-970.
- Fausett, L. 1994. *Fundamentals of Neural Networks: Architectures, Algorithms, and Applications*. New Jersey: Prentice-Hall.
- Hardianto, H. N. I., Suyanto, & Purnama, B. 2011. Analisis dan Implementasi Diferential Evolution dan Recurrent Neural Network untuk Prediksi Data Time Series Studi Kasus Kurs Jual Emas. *Tugas Akhir*. Universitas Telkom.
- Hikmah, A. 2017. Peramalan Deret Waktu Menggunakan Autoregressive (AR), Jaringan Syaraf Tiruan Radial Basis Function (RBF), dan Hibrid AR-RBF pada Inflasi Indonesia. *Unnes Journal of Mathematics* 7(2): 1-14.
- Kaastra, I., & Boyd, M. 1996. Designing a Neural Network for Forecasting Financial and Economic Time Series. *Neurocomputing* 10: 215-236.
- Kohzadi, N., Boyd, M. S., Kermanshahi, B., & Kaastra, I. 1996. A Comparison of Artificial Neural Network and Time Series Models for Forecasting Commodity Prices. *Neurocomputing* 10: 169-181.
- Kontan. 2017. Permintaan Semen Nasional Tumbuh 7,8%. <http://industri.kontan.co.id/news/permintaan-semen-nasional-tumbuh-78>. (diakses tanggal 21 April 2018).
- Kusumadewi, F. 2014. Peramalan Harga Emas Menggunakan Feedforward Neural Networks Dengan Algoritma Backpropagation. *Skrripsi*. Universitas Negeri Yogyakarta.
- Pakaja, F., Naba, A., & Purwanto. 2012. Peramalan Penjualan Mobil Menggunakan Jaringan Syaraf Tiruan dan Certainty Factor. *Jurnal EECCIS* 6(1): 23-28.
- Portal BUMN. 2013. Semen Indonesia Waspada Ketatnya Persaingan Bisnis Semen. <http://bumn.go.id/semenindonesia/berita/703/Semen.Indonesia>. (diakses tanggal 20 April 2018).
- Portal BUMN. 2018. Semen Indonesia Optimis Kelebihan Pasokan Semen Tahun Ini Menyusut. <http://bumn.go.id/semenindonesia/berita/1-Semen-Indonesia-optimis-kelebihan-pasokan-semen-tahun-ini-menyusut>. (diakses tanggal 20 April 2018).
- Puspitaningrum, D. 2006. *Pengantar Jaringan Saraf Tiruan*. Yogyakarta: ANDI.
- Ren, C., An, N., Wang, J., Li, L., Hu, B., & Shang, D. 2014. Optimal Parameters Selection for BP Neural Network Based on Particle Swarm Optimization: A Case Study of Wind Speed Forecasting. *Knowledge-Based Systems* 56: 226-239.
- Rizal, A. A., & Hartati, S. 2017. Prediksi Kunjungan Wisatawan dengan Recurrent Neural Network Extended Kalman Filter. *Jurnal Ilmiah Ilmu Komputer* 10(1): 7-18.
- Salman, A. G., & Prasetyo, Y. L. 2010. Implementasi Jaringan Syaraf Tiruan Recurrent Dengan Metode Pembelajaran Gradient Adaptive Learning Rate untuk Pendugaan Curah Hujan Berdasarkan Peubah ENSO. *Jurnal ComTech* 1(2): 418-429.
- Semen Indonesia. 2017. Permintaan Semen Bakal Terus Naik. <http://www.semenindonesia.com/permintaan-semen-bakal-terus-naik/>.
- Siang, J. J. 2004. *Jaringan Syaraf Tiruan dan Pemrogramannya Menggunakan Matlab*. Yogyakarta: Penerbit Andi.
- Suhada, B. 2009. Peramalan Produksi Gula Nasional Melalui Pendekatan Artificial Neural Network. *Jurnal Derivatif* 3(1): 50-63.
- Susanti, L. A. D., Arna, F., & Sethiawardana. 2013. Peramalan Harga Saham Menggunakan Recurrent Neural Network dengan Algoritma

- Backpropagation Through Time (BPTT). *Makalah Proyek Akhir*. Surabaya: Institut Teknologi Sepuluh Nopember.
- Valipour, M., Banihabib, M. E., & Behbahani, S. M. R. 2013. Comparison of the ARMA, ARIMA, and the Autoregressive Artificial Neural Network Models in Forecasting the Monthly Inflow of Dez Dam Reservoir. *Journal of Hydrology* (online) 476: 433-441.
- Udin, M., Kaloko, B. S., & Hardianto, T. 2017. Peramalan Kapasitas Baterai Lead Acid pada Mobil Listrik Berbasis Levenberg Marquardt Neural Network. *Berkala Saintek* 5(2): 112-117.
- Walid, Subanar, Rosadi, D., & Suhartono. 2015. Fractional Integrated Recurrent Neural Network (FIRNN) for Forecasting of Time Series Data in Electricity Load in Jawa-Bali. *Contemporary Engineering Sciences*. Vol. 8(32): 1535-1550.
- Wang, L., Wang, Z. G., & Liu, S. 2018. Optimal Forecast Combination Based on Neural Networks for Time Series Forecasting. *Applied Soft Computing Journal* 66: 1-17.
- Wikipedia. 2018. Semen Indonesia. [http://id.wikipedia.org/wiki/Semen\\_Indonesia](http://id.wikipedia.org/wiki/Semen_Indonesia). (diakses tanggal 18 April 2018).
- Yang, Y., Hu, J., Lv, Y., & Zhang, M. 2013. Predictions on the Development Dimensions of Provincial Tourism Discipline Based on the Artificial Neural Network BP Model. *Higher Education Studies* 3(3): 13-20.
- Zhang, G. P. 2004. *Business Forecasting with Artificial Neural Networks: An Overview*. Hershey, PA: Idea Group Publishing.
- Zhang, G., & Hu, M. Y. 1998. Neural Network Forecasting of the British Pound/US Dollar Exchange Rate. *Omega* 26(4): 495-506.