

PREDIKSI JUMLAH PERMINTAAN KORAN MENGGUNAKAN METODE EXTREME LEARNING MACHINE

Amalia Ramadhanty¹, Imam Cholissodin, S.Si, M.Kom², Candra Dewi, S.Kom, M.Sc³

Program Studi Teknik Informatika

Fakultas Ilmu Komputer

Universitas Brawijaya, Malang

email: ¹amaliaramadhanty7[at]gmail.com, ²imamcs[at]ub.ac.id, ³dewi_candra[at]ub.ac.id

Abstrak

Kebutuhan masyarakat akan informasi semakin meningkat. Koran merupakan sumber berita dan informasi yang masih tetap digunakan oleh masyarakat Indonesia. Meskipun terdapat berbagai alternatif sumber berita lain, namun koran mempunyai nilai yang tidak dapat digantikan oleh berbagai jenis media elektronik lainnya karena kebenaran informasi yang terjamin dan lebih akurat. Sehingga minat masyarakat untuk membeli koran sebagai sumber berita juga masih besar. Namun tidak bisa dipastikan jumlah permintaan koran setiap harinya karena jumlah permintaan eceran yang tidak menentu. Hal ini menyebabkan semakin sulit bagi perusahaan koran untuk menentukan jumlah koran yang akan diproduksi. Dengan adanya perencanaan produksi yang tepat akan menghasilkan efisiensi jumlah koran dan meningkatkan keuntungan perusahaan. Prediksi yang akurat dan efektif dapat membantu menentukan jumlah permintaan koran yang efisien. Banyak metode yang telah digunakan dalam kasus prediksi. Metode ELM adalah salah satu metode yang bisa digunakan dalam kasus prediksi. Metode ELM dapat digunakan untuk memprediksi jumlah permintaan koran yang menghasilkan nilai *error* kecil. Sesuai dengan pengujian yang telah dilakukan dengan menggunakan data permintaan koran Jawa Pos Radar Madura tahun 2015 tingkat kesalahan yang rendah dihitung dengan MSE yaitu sebesar 0.009311.

Kata kunci: Koran, *Extreme Learning Machine*, Mean Square Error (MSE)

Abstract

The public need for information is increasing. Newspapers are a source of news and information is still being used by Indonesian people. While there are many other alternative news sources, but the newspaper has a value that can not be replaced by various other types of electronic media for the truth of the information secure and more accurate. So that the public interest to buy newspapers as news source is still great. However it is not certain amount of requests daily newspaper for the number of retail demand is erratic. This causes more difficult for newspaper companies to determine the amount of paper to be produced. With the proper planning of production will generate efficiencies number of newspapers and increase corporate profits. Accurate and effective prediction can help determine the amount of demand for efficiency of newspaper. Many methods have been used in the case of prediction. ELM method is one method that can be used in the case of prediction. ELM methods can be used to predict the number of requests that newspapers generate an error value is small. In accordance with the testing that has been done using demand data newspaper Jawa Pos Radar Madura 2015 low error rate calculated by MSE is equal to 0.009311.

Keywords: Newspapers, *Extreme Learning Machine*, Mean Square Error (MSE)

1. PENDAHULUAN

Koran menurut Kamus Besar Bahasa Indonesia (KBBI) adalah lembaran-lembaran kertas bertuliskan kabar (berita) dan sebagainya, yang terbagi dalam kolom-kolom (8—9 kolom), dan terbit setiap hari atau secara periodik. Koran merupakan sumber berita yang masih tetap digunakan oleh masyarakat Indonesia. Meskipun terdapat berbagai alternatif sumber berita lain seperti radio, televisi dan internet, namun koran mempunyai nilai yang tidak dapat digantikan oleh berbagai jenis media elektronik lainnya karena kebenaran informasi yang terjamin dan lebih akurat^[3]. Berdasarkan data survei yang dilansir oleh Mars Indonesia tahun 2009,

pembaca koran dengan membeli secara berlangganan sebanyak 15, 1 %, sementara itu pembaca yang membeli eceran sebanyak 54, 9 %, dan sisanya adalah pembaca koran tetapi tidak membeli koran. Hal ini membuktikan bahwa minat masyarakat untuk membeli koran masih besar. Meski pembeli koran banyak namun tidak bisa dipastikan jumlah pembeli koran setiap harinya karena jumlah permintaan koran yang tidak menentu.

Permintaan koran ada permintaan langganan atau permintaan tetap dan ada permintaan eceran. Permintaan eceran merupakan permintaan yang tidak pasti atau selalu berubah setiap harinya. Sehingga jumlah produksi koran setiap harinya tidak tetap. Sangat penting untuk perusahaan koran

melakukan prediksi terhadap jumlah permintaan koran dengan tujuan mendapatkan laba optimal dan jumlah produksi yang efisien.

Prediksi yang akurat dan efektif dapat membantu menentukan jumlah permintaan koran, sehingga koran yang akan diproduksi akan menghasilkan jumlah yang efisien dan mendapatkan laba yang optimal.

Banyak metode yang telah dilakukan untuk mendapatkan hasil prediksi yang akurat pada kasus-kasus prediksi. Salah satu metode yang bisa dilakukan yaitu *Extreme Learning Machine* (ELM) yang menggunakan data di masa lampau untuk memprediksi di masa mendatang. Hasil penelitian menunjukkan bahwa metode ELM ini sangat menjanjikan untuk permasalahan *time series prediction*^[6]. Penelitian lain juga menunjukkan proses peramalan menggunakan metode ELM menunjukkan tingkat kesalahan yang lebih kecil daripada menggunakan metode *Backpropagation*^[4].

Berdasarkan permasalahan tersebut, solusi yang ditawarkan adalah prediksi jumlah permintaan koran menggunakan metode *Extreme Learning Machine*. Harapan dari implementasi ini dapat membantu perusahaan koran dalam memprediksi jumlah permintaan koran sehingga mendapat laba yang optimal.

2. DASAR TEORI

2.1. Koran

Menurut Jhon Tabbel dalam bukunya yang berjudul *Karier Jurnalistik*, pengertian koran adalah rangkuman semua isi berita yang ditulis melalui media cetak sebagai sarana komunikasi massa, dimana koran ini diperuntukkan untuk umum yang menyangkut kepentingan umum, serta berita yang disajikan dalam koran tersusun dalam alinea kalimat yang mencetak pada kertas^[8].

Radar Madura adalah salah satu perusahaan koran harian yang berpusat di Bangkalan, Madura, Jawa Timur. Radar Madura merupakan bagian dari Jawa Pos Group, Jawa Pos Group ini sendiri tersebar pada seluruh daerah di Indonesia. Jawa Pos Radar Madura merupakan koran harian terbesar di Madura dan merupakan koran harian dengan tingkat oplah terbesar di Madura, pada tahun 2015 rata-rata mencapai 244.946 eksemplar per bulannya^[9].

2.2. *Extreme Learning Machine* (ELM)


Extreme Learning Machine (ELM) merupakan metode pembelajaran baru dari JST. ELM adalah jaringan syaraf tiruan *feedforward* sederhana dengan satu *hidden layer* yang lebih dikenal dengan istilah *Single Hidden Layer Feedforward Neural Networks* (SLFNs)^[7].

Metode ELM ini dibuat untuk mengurangi kelemahan-kelemahan JST *feedforward* terutama mengenai *learning speed*. Huang et al mengemukakan alasan mengapa JST *feedforward* memiliki *learning speed* rendah, yaitu:

1. Menggunakan *slow gradient based learning algorithm* untuk melakukan *training*.
2. Semua parameter pada jaringan ditentukan secara *iterative* dengan menggunakan metode pembelajaran tersebut.

Secara umum, semua parameter dari jaringan *feedforward* ditentukan secara manual. Parameter yang dimaksud yaitu *input weight* dan *bias*. Parameter tersebut saling berhubungan antara *layer* yang satu dengan yang lain, sehingga membutuhkan *learning speed* yang lama^[1]. Pada ELM parameter-parameter tersebut dipilih secara *random* dari nilai tertentu, sehingga ELM memiliki *learning speed* yang cepat.

Secara umum model jaringan syaraf tiruan yang menggunakan ELM sebagai metode pembelajarannya menurut Huang, dkk. dapat dilihat pada Gambar 1.



Gambar 1 Arsitektur ELM

Langkah-langkah perhitungan dengan metode ELM ini dibedakan menjadi 2 proses, yaitu proses *training* dan proses *testing*.

2.2.1 Proses Training

Tujuan dari proses ini adalah mendapatkan *output weight* dengan tingkat kesalahan yang rendah. Langkah-langkah proses *training* metode ELM yaitu sebagai berikut:

1. Inisialisasi *input weight* dan *bias* dengan bilangan acak yang kecil dengan *range* -1 hingga 1^[5].
2. Menghitung semua keluaran di *hidden layer* dengan menggunakan fungsi aktivasi. Setelah keluaran *hidden layer* (H_{init}) didapatkan menggunakan Persamaan 1, kemudian dihitung dengan menggunakan fungsi aktivasi.

$$H_{init\ ij} = \left(\sum_{k=1}^n w_{jk} \cdot x_{ik} \right) + b_j \quad (1)$$

Keterangan:

H_{init} = Matriks keluaran *hidden layer*.

i = [1, 2,, N], dimana N adalah jumlah data.

j = [1, 2,, $\tilde{N}$], dimana $\tilde{N}$ adalah jumlah *hidden neuron*.

n = Jumlah *input neuron*.

w = Bobot *input*.

x = *Input*.

b = *Bias*.

3. Menghitung *output weight* dari *hidden layer* ke *output layer* menggunakan Persamaan 2.

$$\beta = H^+ T \quad (2)$$

Keterangan:

β = Matriks *Output weight* dari *hidden layer* ke *output layer*.

H^+ = Matriks *Moore-Penrose Generalized Invers* dari matriks H .

T = Matriks *Target*

Menghitung matriks *Moore-Penrose Generalized Invers* menggunakan Persamaan 3.

$$H^+ = (H^t H)^{-1} H^t \quad (3)$$

Keterangan:

H^+ = Matriks *Moore-Penrose Generalized Invers* dari matriks H .

H^t = *Transpose* dari matriks H .

H = Matriks keluaran *hidden layer* dengan fungsi aktivasi.

2.2.2 Proses *Testing*

Langkah-langkah proses *testing* yaitu sebagai berikut:

1. Inisialisasi *input weight* dan *bias* yang didapatkan pada perhitungan *training*.
2. Menghitung semua keluaran di *hidden layer* dengan menggunakan fungsi aktivasi ($H(x)$) menggunakan Persamaan 1.
3. Menggunakan hasil *output weight* dari proses *training* untuk menghitung keluaran di *output layer* yang merupakan *output* hasil prediksi.
4. Menghitung *output* menggunakan Persamaan 4.

$$y = H\beta \quad (4)$$

Keterangan:

y = *Output* hasil prediksi.

β = *Output weight*.

H = Keluaran *Hidden layer* dengan fungsi aktivasi.

2.3. Mean Square Error (MSE)

Mean Square Error (MSE) adalah metode untuk mengevaluasi hasil prediksi. Masing-masing kesalahan atau sisa dikuadratkan. Data dengan skala yang berbeda tidak dapat menggunakan MSE sebagai metode evaluasi peramalan^[2]. Untuk menghitung MSE menggunakan Persamaan 5.

$$MSE = \frac{\sum_{i=1}^n e_i^2}{n} = \frac{\sum_{i=1}^n (y_i - t_i)^2}{n} \quad (5)$$

Keterangan:

n = Jumlah data

e = *Error*

y_i = Nilai *output* (prediksi)

t_i = Nilai aktual

2.4. Normalisasi

Metode normalisasi yang digunakan adalah *Min-Max Normalization*, metode ini mengubah data ke *range* baru lain yaitu antara 0 sampai 1. Untuk menghitung normalisasi data menggunakan Persamaan 6.

$$x' = \frac{x - \min}{\max - \min} \quad (6)$$

Keterangan:

x' = nilai data setelah dinormalisasi

x = nilai data sebelum dinormalisasi

$\min$ = nilai minimum pada data set

$\max$ = nilai maksimal pada data set

2.5. Denormalisasi

Denormalisasi data digunakan untuk mendapatkan nilai sebenarnya dari *output* berdasarkan hasil *output* prediksi. Proses denormalisasi data adalah sebagai berikut. Untuk menghitung denormalisasi data menggunakan Persamaan 7.

$$x = x'(\max - \min) + \min \quad (7)$$

Keterangan:

x' = nilai data sebelum didenormalisasi


x = nilai data sesudah didenormalisasi

$\min$ = nilai minimum pada data set

$\max$ = nilai maksimal pada data set

3. METODOLOGI

Untuk dapat memberikan kemudahan dalam menjelaskan metodologi yang digunakan, maka akan dijelaskan menggunakan diagram alir seperti yang tertera pada Gambar 2.



Gambar 2 Diagram Alir


3.1. Data

Pengumpulan data dilakukan dengan melakukan observasi pada perusahaan koran yaitu Radar Madura, melakukan wawancara dengan narasumber dari kepala bagian sirkulasi Radar Madura dan juga dari literatur buku-buku yang terkait. Data dalam penelitian ini berupa jumlah permintaan koran harian selama satu tahun. Data-data pada penelitian ini digunakan untuk menghitung prediksi jumlah permintaan koran menggunakan metode *Extreme Learning Machine* yang kemudian akan dihitung tingkat *error* dari hasil prediksi tersebut.

Data yang digunakan pada penelitian ini adalah data permintaan koran harian pada perusahaan koran Radar Madura tahun 2015 yang didapatkan dari bagian sirkulasi Jawa Pos Radar Madura. Data yang diperoleh sebanyak 363.

4. PERANCANGAN

Perancangan proses prediksi jumlah permintaan koran menggunakan metode ELM ditunjukkan pada Gambar 3 sebagai berikut.



Gambar 3 Diagram Alir Proses Prediksi Jumlah Permintaan Koran

Langkah-langkah proses prediksi data permintaan koran menggunakan metode ELM berdasarkan Gambar 3 adalah sebagai berikut:

1. Sistem menerima masukan berupa data permintaan koran, jumlah *neuron* pada *hidden layer*, fungsi aktivasi yang digunakan dan perbandingan jumlah data *training* dan *testing*
2. Inisialisasi *input weight* dan *bias*
3. Menghitung normalisasi data menggunakan Persamaan 5.
4. Melakukan proses *training* menggunakan data yang telah di normalisasi.
5. Melakukan proses *testing* untuk proses prediksi.
6. Menghitung nilai MSE untuk mengevaluasi hasil prediksi proses *testing* menggunakan Persamaan 4.
7. Menghitung denormalisasi untuk hasil akhir proses *testing* menggunakan Persamaan 6.

8. Keluaran sistem adalah hasil prediksi setelah didenormalisasi

5. IMPLEMENTASI

Implementasi antarmuka prediksi jumlah permintaan koran menggunakan ELM berisi masukan data yang diproses dan ditampilkan pada tabel data, normalisasi, *training*, *testing*, dan denormalisasi. Hasil implementasi ditunjukkan pada Gambar 4 sebagai berikut.


Data ke-	X1	X2	X3	X4	T
1	7899.0	7961.0	7550.0	8166.0	7898.0
2	7961.0	7560.0	8166.0	7898.0	7911.0
3	7560.0	8166.0	7898.0	7911.0	7987.0
4	8166.0	7898.0	7911.0	7987.0	7947.0
5	7898.0	7911.0	7987.0	7947.0	7836.0
6	7911.0	7987.0	7947.0	7836.0	8206.0
7	7987.0	7947.0	7836.0	8206.0	8052.0
8	7947.0	7836.0	8206.0	8052.0	8072.0
9	7836.0	8206.0	8052.0	8072.0	7906.0
10	8206.0	8052.0	8072.0	7906.0	7990.0
11	8052.0	8072.0	7906.0	7990.0	7962.0
12	8072.0	7906.0	7990.0	7962.0	7922.0
13	7906.0	7990.0	7962.0	7922.0	8237.0
14	7990.0	7962.0	7922.0	8237.0	8066.0
15	7962.0	7922.0	8237.0	8066.0	7933.0
16	7922.0	8237.0	8066.0	7933.0	8071.0
17	8237.0	8066.0	7933.0	8071.0	8286.0
18	8066.0	7933.0	8071.0	8286.0	8165.0
19	7933.0	8071.0	8286.0	8165.0	7960.0
20	8071.0	8286.0	8165.0	7960.0	8325.0
21	8286.0	8165.0	7960.0	8325.0	8131.0
22	8165.0	7960.0	8325.0	8131.0	7996.0
23	7960.0	8325.0	8131.0	7996.0	8118.0
24	8131.0	7996.0	8118.0	8063.0	8063.0

Gambar 4 Antarmuka Sistem

6. PENGUJIAN DAN ANALISIS

6.1 Pengujian Jumlah Neuron Pada Hidden Layer

Pengujian jumlah *neuron* pada *hidden layer* bertujuan untuk mendapatkan hasil pengenalan yang lebih baik. Grafik hasil pengujian jumlah *neuron* pada *hidden layer* ditunjukkan pada Gambar 5 berikut ini.




Gambar 5 Grafik Hasil Pengujian Jumlah Neuron Pada Hidden Layer

Berdasarkan grafik pada Gambar 5, semakin banyak jumlah *neuron* pada *hidden layer*, semakin kecil rata-rata nilai MSE yang didapatkan. Dari hasil pengujian yang telah dilakukan, didapatkan rata-rata

nilai MSE sebesar 0.012662 dengan jumlah *neuron* pada *hidden layer* sebanyak 7. Jumlah *hidden neuron* yang semakin banyak akan membentuk banyak penghubung (*connector*) dengan *input layer* dan *output layer*. Kondisi ini memungkinkan unit pemroses pada sistem yang melakukan proses pembobotan untuk mengenali data memiliki kemampuan yang baik dengan semakin banyaknya pertimbangan keputusan yang dilakukan oleh *hidden neuron*.

6.2 Pengujian Fungsi Aktivasi

Pengujian fungsi aktivasi dilakukan untuk mentransformasikan suatu *input* menjadi suatu *output* tertentu. Grafik hasil pengujian fungsi aktivasi ditunjukkan pada Gambar 6 sebagai berikut.




Gambar 6 Grafik Hasil Pengujian Fungsi Aktivasi

Berdasarkan Gambar 6, rata-rata nilai MSE terkecil yang didapatkan adalah menggunakan fungsi aktivasi *sigmoid*. Dari hasil pengujian yang telah dilakukan, didapatkan rata-rata nilai MSE sebesar 0.054712 menggunakan fungsi aktivasi *sigmoid*. Hal ini menunjukkan bahwa dengan fungsi aktivasi *sigmoid* hasil prediksi yang didapat memiliki akurasi lebih baik dibandingkan dengan menggunakan fungsi aktivasi *sin*. Oleh karena itu, fungsi aktivasi *sigmoid* ini lebih banyak dipakai, dibanding fungsi aktivasi *sin*.

6.3 Pengujian Perbandingan Jumlah Data Training dan Data Testing

Pengujian perbandingan jumlah data *training* dan data *testing* ini dilakukan untuk mengetahui pengaruh dari perbandingan jumlah data *training* dengan data *testing* terhadap nilai MSE yang dihasilkan. Grafik hasil pengujian perbandingan jumlah data *training* dan data *testing* ditunjukkan pada Gambar 7 sebagai berikut.

Pengujian Perbandingan Jumlah Data Training dan Data Testing




Gambar 7 Grafik Hasil Pengujian Perbandingan Jumlah Data Training dan Data Testing

Berdasarkan grafik pada Gambar 7, nilai MSE terkecil didapatkan pada perbandingan jumlah data *training* sebanyak 80% dan data *testing* sebanyak 20% yaitu rata-rata nilai *error* sebesar 0.0598783. Banyaknya jumlah data *training* dan data *testing* pada ELM ini berpengaruh terhadap nilai *error* yang dihasilkan. Hal ini disebabkan karena metode ELM merupakan metode pelatihan. Sehingga makin banyak data latih akan semakin baik hasil prediksi yang diperoleh.

6.4 Pengujian Variasi Fitur Data

Pengujian variasi fitur data dilakukan untuk mengetahui pengaruh dari jumlah fitur yang digunakan terhadap nilai MSE yang dihasilkan. Grafik hasil pengujian variasi fitur data ditunjukkan pada Gambar 8 sebagai berikut.

Pengujian Variasi Fitur Data




Gambar 8 Grafik Hasil Pengujian Variasi Fitur Data

Berdasarkan grafik pada Gambar 8, nilai MSE terkecil didapatkan pada jumlah fitur sebanyak 7 dengan rata-rata sebesar 0.010099. Semakin banyak jumlah fitur belum tentu menghasilkan prediksi yang baik, karena tergantung juga dengan objek dan fitur yang digunakan untuk memprediksi.

6.5 Pengujian Berdasarkan Hari yang Sama

Pengujian berdasarkan hari dilakukan untuk mengetahui pengaruh hari yang digunakan terhadap nilai MSE yang dihasilkan. Grafik hasil pengujian berdasarkan hari yang sama ditunjukkan pada Gambar 9 sebagai berikut.

Pengujian Berdasarkan Hari yang Sama




Gambar 9 Grafik Hasil Pengujian Berdasarkan Hari yang Sama

Berdasarkan grafik pada Gambar 9, nilai rata-rata MSE paling kecil didapatkan pada hari Senin sebesar 0.0099049. Pengujian ini menunjukkan bahwa pada hari Senin jumlah permintaan cenderung stabil, bisa dilihat dari nilai rata-rata MSE yang kecil.

6.6 Analisis

Analisis ini bertujuan untuk menampilkan hasil prediksi dibandingkan dengan data aktual dari keseluruhan data yang ada dengan menggunakan 6 *hidden neuron*, fungsi aktivasi *sigmoid*, 7 fitur data, dan perbandingan jumlah data *training* dan data *testing* yaitu 80:20%. Grafik hasil prediksi dengan nilai MSE sebesar 0.010798 yang dibandingkan dengan data aktual ditunjukkan pada Gambar 9.

Perbandingan Hasil Prediksi dan Aktual



Gambar 9 Grafik Perbandingan Hasil Prediksi Dengan Data Aktual

7. PENUTUP

7.1 Kesimpulan

Berdasarkan hasil pengujian dan pembahasan dari prediksi jumlah permintaan koran menggunakan metode *Extreme Learning Machine* (ELM) maka diperoleh kesimpulan sebagai berikut:

1. Metode ELM dapat digunakan untuk memprediksi jumlah permintaan koran yang menghasilkan nilai *error* kecil dengan melibatkan jumlah *neuron* pada *hidden layer*. Banyaknya *neuron* pada *hidden layer* mempengaruhi hasil perhitungan dari suatu permasalahan dimana *hidden neuron* mengolah semua masukan yang nantinya menjadi keluaran.
2. Perbandingan jumlah data *training* dan data *testing* serta penambahan jumlah *neuron* pada *hidden layer* berpengaruh terhadap *output* prediksi yang dihasilkan. Tingkat kesalahan yang rendah berdasarkan pengujian yang dilakukan dengan nilai MSE yaitu sebesar 0.009311 menggunakan fungsi aktivasi *sigmoid*, menggunakan 7 fitur, perbandingan jumlah data *training* dan data *testing* yaitu 80%:20% serta jumlah *hidden neuron* sebanyak 6.

7.2 Saran

Penelitian tentang prediksi menggunakan metode *Extreme Learning Machine* (ELM) dapat dikembangkan dengan beberapa saran sebagai berikut:

1. Untuk penelitian selanjutnya, peneliti dapat menambahkan fitur lain yang merupakan faktor-faktor dalam prediksi jumlah permintaan koran. Hal ini bertujuan agar hasil prediksi lebih obyektif.
2. Pengembangan metode atau penggabungan metode lain dengan ELM seperti *Optimally Pruned Extreme Learning Machine* (OPELM) dapat digunakan pada penelitian selanjutnya untuk meningkatkan hasil prediksi.
3. Pada penelitian selanjutnya juga diharapkan peneliti dapat menambahkan untuk prediksi sampai beberapa hari ke depan, tidak hanya satu hari saja.

8. DAFTAR PUSTAKA

- [1] Huang, G.B., Zhu, Q.Y., dan Siew, C.K. 2005. *Extreme Learning Machine: Theory and*

applications. Elsevier science: Neurocomputing, 70(2006), p.489-501.

[2] Hyndman, Rob J., Koehler, Anne B. 2005. Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22, p.679-688.

[3] JPNN. 2015. Inilah Empat Koran dengan Pembaca Terbanyak. [Online] JPNN.com. Tersedia di <<http://www.jpnn.com/read/2015/04/16/298324/Inilah-Empat-Koran-dengan-Pembaca-Terbanyak->> [Diakses 10 Februari 2016].

[4] Khotimah, Bain K., Sari, Eka Mala R., & Yulianarta, Handry. 2010. Kinerja Metode *Extreme Learning Machine*(ELM) Pada Sistem Peramalan. *Jurnal Simantec*, Vol 1, p.186.

[5] Liang, Nan-Ying, Huang, Guang-Bin, Saratchandran, P., & Sundararajan, N., 2006. A Fast and Accurate Online Sequential Learning Algorithm for Feedforward Networks. *IEEE Transactions On Neural Networks*, Vol 17(6), p.1411-1423.

[6] Singh, R. & Balasundaram, S., 2007. Application of *Extreme Learning Machine* Method for Time Series Analysis. *International Journal of Intelligent Technology*, 2(4), p.256.

[7] Sun, Z.L., Choi, T.M., Au, K.F., dan Yu, Y. 2008. Sales Forecasting using *Extreme Learning Machine* with Application in Fashion Retailing. *Elsevier Decision Support Systems*, 46(2008), p.411-419.

[8] Tabbel, John. 2003. *Karier Jurnalistik*. Semarang: Dhara Prize.

[9] Wijono, Ari. 2016. Wawancara Jumlah Permintaan Koran Radar Madura. Diwawancarai oleh Amalia Ramadhanty. Lawang, 23 April 2016.