

# Prediksi Kebutuhan Arus Proteksi Pada *Underground Impressed Current Cathodic Protection (ICCP)* Dengan Menggunakan *Artificial Neural Network*

Rifqi A. Tanjung, Mas Irfan P. Hidayat and Tubagus N. Rohmannudin  
 Jurusan Teknik Material & Metalurgi, Fakultas Teknologi Industri  
 Institut Teknologi Sepuluh Nopember (ITS)  
 Jl. Arief Rahman Hakim, Surabaya 60111 Indonesia  
 e-mail: irfan@mat-eng.its.ac.id

**Abstrak**— Untuk dapat menghasilkan desain proteksi katodik arus paksa (ICCP) perlu dilakukan perhitungan kebutuhan arus proteksi yang tepat agar proteksi katodik dapat berjalan dengan optimal. Penelitian ini berfokus pada prediksi kebutuhan arus proteksi yang optimal untuk aplikasi ICCP dalam tanah dengan menggunakan neural network (NN). Modeling dengan menggunakan NN dilakukan dengan menggunakan data yang memiliki beda derajat keasaman (pH), coating parameters dan waktu proteksi. Data dari 2080 kondisi berbeda diinput pada NN sebagai training data. NN yang digunakan dalam penelitian kali ini adalah jenis multilayer perceptron (MLP) dan hasil prediksi kebutuhan arus proteksi. Kemudian hasil training dari MLP NN ini disimulasi menggunakan 25 data testing dan menghasilkan 3 model terbaik dengan struktur MLP Feedforward-Backpropagation yang memiliki jumlah neuron 26, 27 dan 28. Model ini memiliki akurasi hingga  $5.24 \times 10^{-3}$ .

**Kata kunci** – Proteksi Katodik Arus Paksa, Prediksi Kebutuhan Arus Proteksi, Various Conditions, Neural Network

## I. PENDAHULUAN

Korosi akan secara natural terjadi dimana ada perbedaan energi potensial. Banyak penelitian sebelum ini telah dilakukan untuk menghasilkan proteksi yang optimal pada komponen atau struktur dari korosi. Salah satu metode yang saat ini umum diketahui dan banyak digunakan dalam industry adalah system proteksi katodik. Pada prinsipnya, proteksi katodik memanfaatkan arus atau perpindahan electron dari anoda yang memiliki potensial negative untuk memproteksi struktur yang memiliki potensial positif (sebagai katoda). Sistem proteksi katodik dengan menggunakan arus atau *Impressed Current Cathodic Protection* (ICCP) akan memaksa material non-isolator untuk menjadi anoda untuk memproteksi struktur. Karena dalam ICCP perubahan arus akan mempengaruhi energy potensialnya, maka arus yang dibutuhkan untuk memproteksi sebuah struktur perlu untuk diketahui yang secara umum diketahui dengan control atau maintenance berkala pada struktur. Hal ini meningkatkan *maintenance cost*, ditambah kondisi lingkungan yang selalu berubah mengakibatkan energi

potensial yang juga selalu berubah dan mempengaruhi efisiensi proteksi.

Inovasi terus dilakukan untuk meningkatkan *protection affectivity* dan *cost efficiency* dalam aplikasinya untuk memproteksi struktur industri. Kontras dengan hal tersebut, biaya inspeksi juga diperhatikan untuk mengefisienkan pengeluaran karena intensitas inspeksi akan meningkatkan pengeluaran namun minimumnya inspeksi akan meningkatkan resiko kegagalan. Oleh karena itu pengembangan dalam bidang automasi pengaturan ICCP ini masih dikembangkan.

Perkiraan kebutuhan arus proteksi akan dapat mengefisienkan system ICCP yang diterapkan. Penelitian telah dilakukan oleh Trendi dan Faris (Trendi, 2014; Faris, 2014) pada ICCP media tanah mengindikasikan adanya pengaruh perbedaan pH pada kebutuhan arus proteksi. Prediksi kebutuhan arus proteksi akan menjadi dasar penggunaan arus awal yang diberlakukan kepada system ICCP dan akan mempengaruhi proteksi yang diberikan kepada struktur. Dalam pengembangannya penelitian ini ditujukan agar dapat menemukan model kebutuhan arus proteksi berdasar jenis material yang digunakan, lingkungan yang mempengaruhi sistem dan kondisi sistem. Model ini akan membantu menentukan arus proteksi awal untuk diterapkan pada sebuah system ICCP. Dan penelitian ini diharap dapat dikembangkan untuk menjadi sebuah alternative metode perhitungan kebutuhan arus proteksi.

## II. PENELITIAN

Langkah pada penelitian ini dibagi menjadi tiga tahap, yaitu:

- Pengolahan Data
- Pembuatan model
- Analisa Model dan Validasi

### A. Pengolahan Data

Penelitian ini akan menggunakan data sekunder, yaitu data yang didapatkan dari penelitian yang pernah dilakukan (penelitian Ardiansyah (2014) dan Pratama (2014)). Data tersebut kemudian akan dibagi menjadi dua:

- Data training : terdiri dari data input ( $i_0$ ) dan data target ( $t_0$ ) yang digunakan *artificial neural network* agar dapat membentuk model yang sesuai. Sehingga jika

disimulasikan dengan data input ( $i_o$ ), dapat menghasilkan data target ( $t_o$ ).

- Data simulasi : terdiri dari data input ( $i_s$ ) akan digunakan sebagai bahan simulasi model dan menghasilkan data output ( $O_s$ ) yang kemudian akan di denormalisasi menjadi data kebutuhan arus proteksi hasil simulasi ( $H_s$ ). Juga terdiri dari data target ( $t_s$ ) yang akan digunakan sebagai pembanding  $H_s$ , semakin dekat  $H_s$  dengan  $t_s$  menandakan semakin baik performa model.

Data ini kemudian di normalisasi atau ubah dengan batas 0 sampai 1 dengan menggunakan persamaan (1) agar data tidak dinamis.

$$N = \frac{Data - D_{min}}{D_{max} - D_{min}} \quad (2)$$

Dengan:

- N = Data hasil Normalisasi  
 D = Data yang akan di Normalisasi  
 $D_{min}$  = Batas bawah data  
 $D_{max}$  = Batas atas data

Kemudian hasil simulasi data normalisasi ini akan di denormalisasi dengan menggunakan persamaan 17 sehingga menghasilkan  $H_s$

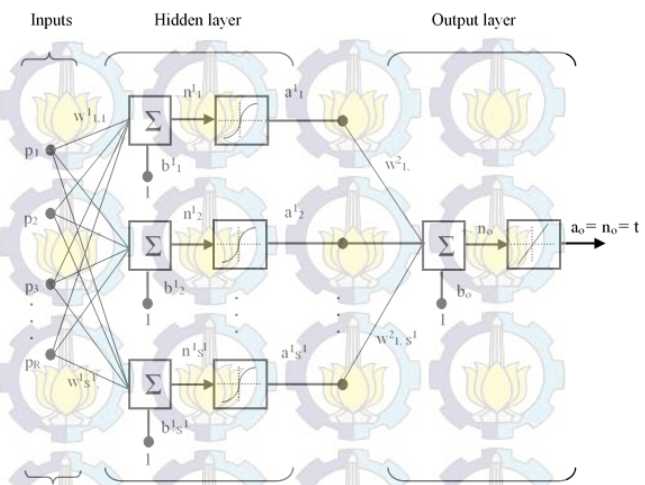
$$D = H \times (D_{max} - D_{min}) + D_{min} \quad (2)$$

Dengan:

- H = Data hasil simulasi (mA)  
 D = Data setelah denormalisasi  
 $D_{min}$  = Batas bawah data  
 $D_{max}$  = Batas atas data

### B. Struktur Neural Network

Dalam penelitian ini, NN dengan tipe Multi-Layer Perceptron (MLP) digunakan untuk simulasi kebutuhan arus proteksi pada system ICCP. Gambar 1 menunjukkan bagaimana bentuk struktur MLP dengan 1 input layer, 1 hidden layer dan 1 output layer. Dengan masing masing tanda mewakili :  $p$  input sets,  $L$  jumlah element pada input vector,  $s$  jumlah hidden nodes,  $n$  input yang telah diberi *weight*,  $a$  output dari fungsi aktifasi pada layer yang bersangkutan,  $w^1_{j,i}$  dan  $b^1_j$  input *weight* dan *bias* ( $i = 1$  hingga  $L$ ,  $j = 1$  hingga  $s$ ),  $w^2_{1,j}$  dan  $b_o$  layer *weight* dan output bias, dan  $y$  adalah output dari MLP. Superscripts 1 dan 2 masing masing menunjukkan hidden layer sebagai layer pertama dan output layer sebagai layer kedua.



Gambar. 1. Struktur MLP dengan satu input layer, satu hidden layer dan satu output layer.

### C. Pembuatan Model Artificial Neural Network

ANN diproses dengan aplikasi MATLAB® R2014a dengan toolbox Neural Network Tool (nntool).

- Membuka Neural Network Tool
- Input  $i_o$  dan  $t_o$
- Membuat model
- Melakukan *training*
- Melakukan simulasi dan menghasilkan  $O_s$
- Melakukan kalibrasi *weight* dan *bias* untuk *training* ulang
- Setelah *training* ulang sebanyak 10 kali, melanjutkan penelitian dengan model baru (jumlah neuron sebagai variable)

### D. Analisa dan Validasi

Analisa yang dilakukan adalah analisa akurasi dan kevalidan prediksi yang dihasilkan oleh model. Hasil yang diharapkan adalah kebutuhan arus proteksi yang dapat diterapkan pada kondisi lapangan (dalam percobaan ini mengacu pada data pengujian lapangan Ardhiansyah (2014) dan Pratama (2014) atau  $t_o$  dan  $t_s$ ).

Setelah dilakukan denormalisasi dari  $O_s$  menjadi  $H_s$ . Validasi dilakukan dengan menggunakan aplikasi Microsoft® Office Excel 2016 dengan batas toleransi sebesar 50% untuk menentukan  $H_s$  mana yang dapat diaplikasikan dan  $H_s$  mana yang tidak dapat diaplikasikan menggunakan rumus excel ( $f_x$ ) berikut:

$$K = \text{if}(\text{and}(H_s > T_{min}, H_s < T_{max}), "A", "B") \quad (3)$$

Dengan:

- K = Keterangan A atau B  
 IF = Fungsi jika pada excel  
 AND = Digunakan untuk menyambung dua rumus  
 T = Batas toleransi atas (max) dan bawah (min)  
 A =  $H_s$  dapat di aplikasikan  
 B =  $H_s$  tidak dapat di Aplikasikan

Untuk mengukur akurasi model, peneliti membandingkan jumlah hasil simulasi yang aplikatif dibandingkan dengan total hasil simulasi dalam bentuk persen dengan persamaan berikut:

$$Akurasi = \frac{N_A}{A + B} \times 100\% \quad (4)$$

Dengan:

$N_A$  = Banyaknya A

A =  $H_s$  yang dapat di aplikasikan

B =  $H_s$  yang tidak dapat di Aplikasikan

E. Implementasi Neural Network

Model neural network yang digunakan pada aplikasi MATLAB® R2014a dengan code nntool akan memberikan kebebasan pengguna memilih fitur yang tersedia, dan pada penelitian kali ini menggunakan spesifikasi model sebagai berikut:

Model menggunakan supervised neural network dengan tipe supervised feedforward backpropagation.

Supervised neural network adalah kategori model yang dilatih agar menghasilkan output yang bergantung pada sampel yang di input, menjadikan model yang sesuai keinginan pengguna.

Feedforward adalah arus network berjalan searah dari input layer melalui hidden layer yang bentuk menuju output layer. Feedforward backpropagation net adalah artificial neural network dengan backpropagation training algoritma yang pada algoritmanya training output dilihat errornya dan kemudian digunakan untuk mengatur ulang weight dan biass pada input dan hidden layer pada saat retrain untuk mengurangi error.

III. HASIL DAN PEMBAHASAN

A. Data Eksperimen

Setelah dilakukan penelitian seperti telah dijelaskan pada bagian metodologi, didapatkan hasil penelitian seperti tertera pada lampiran. Dengan menggunakan tipe jaringan feed-forward backpropagation, percobaan ini mencoba mencari jumlah neuron yang menghasilkan prediksi optimal pada range 5 hingga 30 jumlah neuron pada hidden layernya.

Tabel 1. Struktur ANN yang digunakan

<b>Aplikasi</b>	MATLAB® R2014a
<b>Tipe Jaringan</b>	Supervised Feed-Forward Backpropagation
<b>Tipe Perceptron</b>	Single Layer
<b>Algoritma</b>	Levenberg-Marquardt Backpropagation
<b>Jumlah Perceptron</b>	5-30


struktur NN ini digunakan pada data input dengan variasi seperti ditunjukkan pada tabel 2

Tabel 2. Material dan tipe data set yang disimulasikan oleh NN

Material	Keasaman (pH)	Parameter coating		Lama proteksi (hours)
		Protected area (%)	Shape	
AISI 1045 Steel	pH: 11, 7, 3	0%, 92%, 96%, 97%, 98%, 99%, 100%	Lingkaran dan persegi	24 jam hingga 184 jam dengan interval 8 jam
API 5L B Grade Steel	pH: 11, 9, 7, 5, 3			

B. Hasil dan Analisa

Pada setiap model, simulasi dilakukan sebanyak sepuluh kali untuk merepresentasikan kebutuhan arus proteksi pada setiap model dengan variasi jumlah hidden node yang digunakan. Gambar 2 menunjukkan akurasi hasil prediksi rata-rata pada setiap model.



Gambar. 2. Perbandingan akurasi model pada setiap jumlah hidden node yang digunakan.

Dapat dilihat dari gambar 2 bahwa model NN dapat mensimulasikan kebutuhan arus proteksi hingga akurasi 87%. Dapat juga dilihat dari grafik bahwa simulasi kebutuhan arus proteksi mencapai akurasi terbaiknya pada model dengan jumlah neuron 14, 15 dan 16 yang memiliki akurasi lebih baik dibandingkan dengan jumlah neuron lain. Atas dasar inilah kemudian model dengan jumlah neuron 14,15 dan 16 dipilih untuk mensimulasikan kebutuhan arus proteksi.

Untuk melihat lebih jauh performa model yang dihasilkan, model dengan jumlah neuron 14,15 dan 16 disimulasi dengan menggunakan 25 data uji seperti ditunjukkan pada tabel 3. Tabel 4 menunjukkan hasil prediksi kebutuhan arus proteksi di setiap titik uji menggunakan masing-masing model.

Tabel 3. Data variable esting set yang digunakan

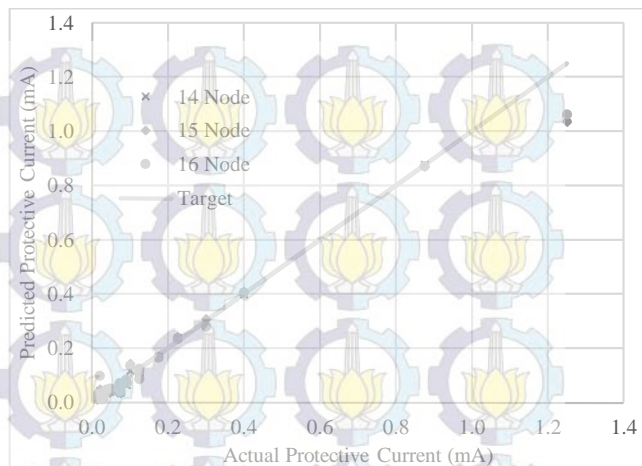
No.	Bahan	Keasaman	Variasi Cacat	Persen Coating	Durasi Proteksi	
1	AISI 1054	pH 3	Lingkaran	98.6%	160 jam	
2		pH 3	-	100.0%	40 jam	
3		pH 3	Persegi	99.3%	112 jam	
4		pH 7	Lingkaran	92.8%	64 jam	
5		pH 7	Persegi	92.8%	160 jam	
6		pH 7	Persegi	99.9%	112 jam	
7		pH 11	Lingkaran	96.4%	88 jam	
8		pH 11	Lingkaran	99.9%	96 jam	
9		pH 11	Persegi	92.8%	80 jam	
10		pH 11	Persegi	99.3%	72 jam	
11		API 5L Gr.B	pH 3	Lingkaran	99.2%	24 jam
12			pH 3	Lingkaran	99.9%	104 jam

13	pH 3	Persegi	98.7%	32 jam
14	pH 3	Persegi	99.5%	160 jam
15	pH 5	-	100.0%	96 jam
16	pH 5	Persegi	98.7%	88 jam
17	pH 5	Persegi	99.7%	40 jam
18	pH 7	Lingkar	99.2%	184 jam
19	pH 7	-	100.0%	144 jam
20	pH 7	Persegi	98.7%	120 jam
21	pH 9	-	0.0%	176 jam
22	pH 9	Persegi	99.2%	152 jam
23	pH 11	Lingkar	99.9%	72 jam
24	pH 11	Persegi	98.7%	96 jam
25	pH 11	Persegi	99.9%	120 jam

Tabel 4. Hasil pengujian menggunakan testing set.

No	Target (mA)	Prediction (mA)			Deviation (mA)		
		14	15	16	14	15	16
1	0.100	0.118	0.143	0.136	0.018	0.043	0.036
2	0.025	0.021	0.014	0.011	0.004	0.011	0.014
3	0.075	0.037	0.034	0.042	0.038	0.041	0.033
4	0.091	0.064	0.077	0.070	0.027	0.014	0.021
5	0.125	0.100	0.084	0.086	0.025	0.041	0.039
6	0.030	0.025	0.012	0.022	0.005	0.018	0.008
7	0.068	0.052	0.035	0.052	0.016	0.033	0.016
8	0.014	0.026	0.009	0.025	0.012	0.005	0.011
9	0.089	0.066	0.086	0.082	0.023	0.003	0.007
10	0.026	0.026	0.023	0.034	0.000	0.003	0.008
11	0.400	0.398	0.409	0.405	0.002	0.009	0.005
12	0.038	0.032	0.042	0.046	0.006	0.004	0.008
13	1.250	1.052	1.033	1.061	0.198	0.217	0.189
14	0.175	0.169	0.171	0.165	0.006	0.004	0.010
15	0.020	0.017	0.013	0.023	0.003	0.007	0.003
16	0.300	0.299	0.309	0.279	0.001	0.009	0.021
17	0.047	0.038	0.037	0.052	0.009	0.010	0.005
18	0.125	0.112	0.094	0.114	0.013	0.031	0.011
19	0.015	0.028	0.019	0.029	0.013	0.004	0.014
20	0.225	0.238	0.241	0.233	0.013	0.016	0.008
21	0.875	0.876	0.868	0.871	0.001	0.007	0.004
22	0.072	0.058	0.060	0.071	0.014	0.012	0.001
23	0.021	0.042	0.049	0.098	0.021	0.028	0.077
24	0.125	0.112	0.123	0.123	0.013	0.002	0.002
25	0.019	0.026	0.032	0.028	0.007	0.013	0.009

Perbandingan hasil prediksi kebutuhan arus proteksi dengan kebutuhan arus proteksi aktual pada model dengan jumlah neuron 14,15 dan 16 ditunjukkan oleh gambar 3 sehingga terlihat jelas performa model dalam mensimulasi kebutuhan arus proteksi dalam system proteksi katodik arus paksa.



Gambar. 3. Perbandingan hasil prediksi dengan nilai aktual kebutuhan arus proteksi pada model dengan jumlah neuron 14, 15 dan 16.

Untuk memperlihatkan lebih jauh performa model dalam memprediksi kebutuhan arus proteksi, tabel 4 menunjukkan deviasi hasil prediksi model pada data testing dengan 25 kondisi berbeda. Dapat kita lihat bahwa model dapat memprediksi kebutuhan arus proteksi dengan baik di berbagai kondisi. Deviasi antara kebutuhan arus aktual dan yang diprediksikan oleh model relative kecil. Hal ini menunjukkan bahwa model NN dapat menghasilkan prediksi kebutuhan arus proteksi pada Proteksi Katodik Arus Paksa dengan akurat.

#### IV. KESIMPULAN

Pada artikel ini, hasil simulasi/prediksi kebutuhan arus proteksi pada system proteksi katodik arus paksa menggunakan *Neural Network* telah dipresentasikan. Telah tersampaikan juga bahwa model *Neural Network* yang dikembangkan dapat menghasilkan kebutuhan arus proteksi yang diinginkan pada kondisi yang berbeda-beda. Hal ini menunjukkan kapabilitas model dalam menghasilkan prediksi yang akurat untuk kebutuhan arus proteksi pada system proteksi katodik arus paksa. Dengan kondisi data seperti disampaikan dalam artikel ini, model terbaik menghasilkan kebutuhan arus proteksi dengan jumlah hidden neuron sebanyak 14, 15 dan 16. Selain itu beberapa model dengan jumlah neuron 13, 18, 19, 26 dan 27 yang memiliki akurasi yang baik juga masih dapat dikembangkan untuk ditingkatkan akurasinya. Hasil simulasi ini menunjukkan adanya peluang untuk mengimplementasikan *Artificial Intelligence* atau *Artificial Neural Network* dalam mengembangkan system proteksi katodik arus paksa. Pengembangan model *Neural Network* untuk korosi pada struktur besar akan menjadi tahap lanjutan dari penelitian ini.

#### DAFTAR PUSTAKA

- [1] Aleksander, I., & Morton, H. (1990). An introduction to neural computing. London: Chapman & Hall.
- [2] Allan, G., Yang, R., Fotheringham, A., & Mather, R. (2001). Neural modelling of polypropylene fiber processing: predicting the structure and properties and identifying the control parameters for specified fiber. *Journal of Materials Science* 36, 3113-3118.
- [3] Al-Masri, A. N., Ab Kadir, M. A., Hizam, H., & Mariun, N. (2015). Simulation of an adaptive artificial neural network for power system

- security enhancement including control action. *Applied Soft Computing*, 1-11.
- [4] Ardiansyah, F. P. (2014). Pengaruh pH Tanah dan Variasi Cacat Gores Lapis Lindung Terhadap Kebutuhan Arus Proteksi Sistem Impressed Current Cathodic Protection (ICCP) pada Baja AISI 1045. Surabaya: Jurusan Teknik Material dan Metalurgi ITS.
- [5] Bishop, C. M. (1995). *Neural network for pattern recognition*. Oxford: Oxford University Press.
- [6] Bribilis, N., Cavanaugh, M. K., Sudholz, A. D., Zhu, S. M., Easton, M. A., & Gibson, M. A. (2011). A combined neural network and mechanistic approach for the prediction of corrosion rate and yield strength of magnesium-rare earth alloys. *Corrosion Science* 53, 168-176.
- [7] Demuth, H., & Beale, M. (2002). *Neural Network Toolbox User's Guide, for Use with MatLab® Ver.4. 3* Apple Hill Drive Natick, MA 01760-2098: The MathWorks, Inc...
- [8] Fausett, L. V. (1994). *Fundamentals of neural networks (1st ed.)*. Englewood Cliffs, NJ: Prentice Hall.
- [9] Hafezi, R., Shahrabi, J., & Hadavandi, E. (2011). A bat-neural network multi-agent system (BNNMAS) for stock price prediction: Case study of DAX stock price. *Applied Soft Computing*, 196-210.
- [10] Hardjowigeno, S. (1995). *Ilmu Tanah*. Jakarta: Akademi Pressindo.
- [11] Hardjowigeno, S. (1997). *Klasifikasi Tanah*. Yogyakarta: Gadjah Mada University Press.
- [12] Haykin, S. S. (1998). *Neural Networks: a comprehensive foundation (2nd ed.)*. Upper Saddle River, NJ: Prentice Hall.
- [13] Kaushik, B., & Banka, H. (2015). Performance evaluation of approximated artificial neural network (AANN) algorithm for reliability improvement. *Applied Soft Computing*, 303-314.
- [14] Kriesel, D. (2005). *A Brief Introduction to Neural Networks*. German: dkriesel.com.
- [15] López-Martín, C. (2015). Predictive accuracy comparison between neural networks and statistical regression for development effort of software projects. *Applied Soft Computing*, 434-449.
- [16] Mänttari, J., & Larsson, J. (2011). *Applications of Artificial Neural Networks in Games*. School of Innovation, Design and Engineering, Västerås: Mälardalen University.
- [17] Pratama, T. L. (2014). Pengaruh variasi goresan lapis lindung dan variasi pH tanah terhadap arus proteksi sistem Impressed Current Cathodic Protection (ICCP) pada pipa API 5L grade B. Surabaya: Jurusan Teknik Material dan Metalurgi ITS.
- [18] Roberge, P. R. (1999). *Handbook of Corrosion Engineering*. New York: McGraw-Hill.
- [19] Shi, J. W. (2015). Prediction of primary water stress corrosion crack growth rates in Alloy 600 using artificial neural networks. *Corrosion Science* 92, 217-227.
- [20] Sobhania, J., & Ramezani-pour, A. A. (2011, July). Service life of the reinforced concrete bridge deck in corrosive environments. *Applied Soft Computing*, 11(4), 3333-3346.
- [21] Swingler, K. (1996). *Applying Neural Networks : a practical guide*. London: Academic Press.
- [22] Trethewey, K. R., & Chamberlain, J. (1988). *CORROSION for Students of Science and Engineering*. UK Limited: Longman Group.

