

# Optimasi Prediksi Kehadiran Pegawai Untuk Intensif Kehadiran Menggunakan Jaringan Saraf Tiruan-*Backpropagation*

Jamaludin Hakim<sup>1)</sup>, Sri Hartati<sup>2)</sup>

<sup>1)</sup>Program Studi Sistem Informasi Fakultas Teknik dan Sistem Informasi  
Universitas YAPIS Papua Jayapura

Jl. Sam Ratulangi No. 11 YAPIS Dok V Atas Jayapura Papua

<sup>2)</sup>Jurusan Ilmu Komputer dan Elektronika

Fakultas Matematika dan Ilmu Pengetahuan Alam  
Universitas Gadjah Mada

Jl. Sekip Utara Bulaksumur Yogyakarta 55281

email : <sup>1)</sup>J2hakim@gmail.com, <sup>2)</sup>shartati@ugm.ac.id

## ABSTRAK

Kehadiran merupakan salah faktor pengukur produktifitas pegawai, untuk itu disetiap lembaga, baik swasta maupun pemerintahan memberikan intensif/tunjangan untuk kehadiran pegawainya. Untuk lembaga swasta perencanaan penganggaran untuk membayar intensif pegawai sangat diperlukan agar pos dana yang digunakan untuk itu tidak berlebih atau bahkan kurang. Untuk itu perlu diprediksi kehadiran pegawai untuk bulan selanjutnya guna memprediksi intensif/tunjangan yang akan dibayarkan. Prediksi akan menggunakan *JST-Backpropagation* dengan menggunakan input data absolut selisih kehadiran tahun lalu dan dua tahun sebelumnya, halangan (sakit, ijin, absen), waktu lewat (melewati batas waktu masuk). Penelitian akan mencoba mencari MSE terkecil untuk tiap penggunaan banyaknya unit dalam hidden layer dan learning rate dalam pelatihan.

**Keywords :** Intensif kehadiran, *JST-Bacpropagation*, learning rate.

## 1. PENDAHULUAN

Kehadiran tiap bulan yang digunakan sebagai pengukur produktifitas pegawai dalam sebuah organisasi hasilnya selalu berubah-ubah, tentunya pembayaran intensif kehadiranpun menjadi beragam tergantung aktifitas yang terjadi pada bulan tersebut.

Pada organisasi swasta pembayaran intensif kehadiran menjadi suatu beban pembiayaan yang perlu direncanakan agar dapat menciptakan efisiensi penggunaan dana untuk tiap bulannya. Untuk maksud tersebut perlu direncanakan pengeluaran untuk membayar intensif kehadiran agar dana yang akan dialokasikan tidak berlebih atau bahkan kurang, agar dana dapat teralokasi secara efektif dan efisien sesuai dengan pos kebutuhannya.

Dengan maksud tersebut maka diperlukan prediksi kehadiran untuk bulan berikutnya agar dapat diketahui besaran biaya intensif yang perlu dialokasikan untuk pembayaran intensif kehadiran, walupun akan muncul anggapan apakah bisa hanya berpatokan pada prekdisi tersebut akan cukup aman untuk alokasi dana intensif, bagaimana jika kurang atau tetap berlebih?, namun dengan prediksi ini kelebihan maupun kekurangan tidak

akan jauh dari kehadiran yang sebenarnya dibandingkan perkiraan yang mengandalkan intuisi, atau bahkan hanya mengandalkan kebiasaan dan mencari aman dalam alokasi dana sehingga menyebabkan kurang efektifnya alokasi pendanaan.

Pada penelitian ini data untuk penelitian yang digunakan adalah milik Universitas YAPIS Papua (UNIYAP) Jayapura, dimana data yang digunakan adalah data kehadiran tahun 2010 dan 2011 dari 87 orang staf dan dosen yang tercatat kehadirannya. Intensif yang digunakan di UNIYAP Jayapura, Rp. 40.000,- (empat puluh ribu) perhari, sehingga perhitungan intensif akan mengacu pada nominal tersebut.

## 2. TINJAUAN PUSTAKA

*Backpropagation* merupakan metode pembelajaran yang menyelesaikan permasalahan prediksi dengan meminimalisasi network cumulative error [6], sehingga dalam proses pembelajaran jaringan nantinya akan mencari error terkecil yang dapat diperoleh dengan melakukan uji coba penggunaan banyaknya hidden layer, unit dan learning rate.

### a. Algoritma *Backpropagation*

**Langkah 0:** inisiasi semua bobot dengan bilangan acak kecil

**Langkah 1:** jika kondisi penghentian belum terpenuhi, lakukan langkah 2-8

**Langkah 2:** untuk setiap pasang data pelatihan, lakukan langkah 3-8

**Fase I: propagasi maju**

**Langkah 3:** Tiap unit masukan menerima sinyal dan meneruskannya ke unit diatasnya

**Langkah 4:** hitung semua keluaran unit tersembunyi

$$= + \quad = - \\ = \frac{1}{1 + -}$$

**Langkah 5:** Hitung semua keluaran jaringan di unit  $y_k$

$$y_k = \frac{1}{1 + e^{-x_k}}$$

**Fase II: Propagasi mundur**

**Langkah 6:** Hitung faktor unit keluaran berdasarkan kesalahan dietip unit keluaran  $y_k = ( \dots ) ( \dots ) = ( \dots ) (1 - \dots)$   
Hitung suku perubahan bobot  $W_{kj}$  dengan laju percepatan

$$\Delta =$$

**Langkah 7:** Hitung faktor unit tersembunyi berdasarkan kesalahan disetiap unit tersembunyi  $z_j$

$$\dots =$$

Faktor  $\delta$  unit tersembunyi :

$$= \dots - \dots = \dots - \dots$$

Hitung suku perubahan bobot  $v_{ji}$

$$\Delta =$$

Fase III: Perubahan bobot

**Langkah 8:** Hitung semua perubahan bobot

Perubahan bobot garis yang menuju unit keluaran :

$$( \dots ) = ( \dots ) + \Delta$$

Perubahan bobot garis yang menuju ke unit tersembunyi :

$$( \dots ) = ( \dots ) + \Delta$$

**b. Transformasi bilangan**

Untuk menghasilkan nilai bobot pelatihan yang maksimal pada jaringan syaraf tiruan dengan backpropagation, maka nilai-nilai input dan target akan ditransformasi terlebih dahulu kedalam range 0,1-0,9 (sigmoid biner [0,1]), dengan menggunakan transformasi linier sebagai berikut:

$$x = \frac{\dots}{\dots} + 0.1 \tag{1}$$

Dan untuk mengembalikan nilai yang telah ditransformasi ke nilai sebenarnya dapat digunakan transformasi linier sebagai berikut :

$$x = \frac{\dots}{\dots} + \min \tag{2}$$

**3. METODE PENELITIAN**

Untuk komputasi dalam penelitian ini akan menggunakan tools yang sudah menyediakan pembentukan JST-Backpropagation [2], dengan pada awal pelatihan akan merancang sebuah jaringan JST-backpropagation menggunakan 1 (satu) lapisan tersembunyi dengan 1 (satu) unit dan terus menambah jumlah unit. pelatihan selanjutnya akan dilakukan dengan penggunaan learning rate yang berbeda-beda. Pada penelitian ini akan menggunakan fungsi aktivasi sigmoid biner sehubungan dengan data yang digunakan akan

ditransformasikan kedalam sigmoid biner. Sebagai indikator optimasi pembelajaran selain MSE yang paling terkecil, digunakan juga Jumlah Epoch dalam pembelajaran.

**a. Input Jaringan**

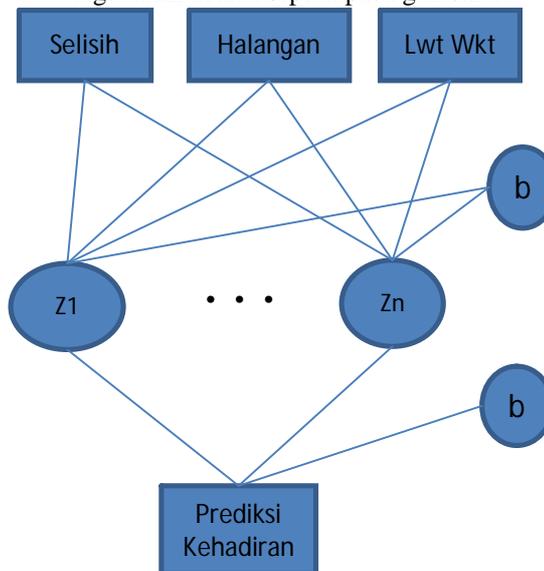
Untuk mendapatkan hasil prekdiksi yang optimal perlu diformulasikan input yang digunakan yang diasumsikan dapat mempengaruhi hasil pembelajaran jaringan. Input yang akan digunakan dan keterangannya dapat dilihat pada tabel 1.

Tabel 1. Input jaringan dan keterangannya

Uraian	Penjelasan
selisih	Nilai absolut selisih kehadiran tahun sebelumnya dengan dua tahun sebelumnya
Halangan	Jumlah halangan karena sakit, ijin dan tanpa keterangan pada tahun/bulan Berjalan
Lewat waktu	Jumlah yang absen namun lewat waktu pada tahun/bulan Berjalan

**b. Arsitektur Jaringan**

Berdasarkan formulasi input yang digunakan untuk pembelajaran jaringan maka jaringan JST-Backpropagation yang akan digunakan adalah seperti pada gambar 1.



Gambar 1. Arsitektur jaringan JST-Backpropagation prediksi kehadiran

**c. Pola Data Pelatihan**

Untuk pelatihan jaringan menggunakan data kehadiran pegawai pada tahun 2009, 2010 dan 2011, dengan rincian, untuk data selisih adalah nilai absolut selisih data kehadiran tahun 2009 dan 2010, data halangan, dan lewat waktu menggunakan data tahun 2010 dan data kehadiran 2011 akan digunakan sebagai target pembelajaran jaringan. Pola data real untuk pelatihan jaringan yang akan digunakan untuk penelitian ini terlihat pada tabel 2.

Tabel 2. Pola data real pelatihan jaringan

POLA	INPUT			Target
	selisih	Halangan	Lwt Wkt	
1	225	192	618	1062
2	518	255	487	1019
3	387	237	209	1283
4	444	259	328	1123
5	169	227	398	1117
6	336	195	212	1273
7	336	273	410	1571
8	127	164	425	1345
9	99	293	619	1531
10	220	161	771	1476
11	3	249	679	1430
12	101	225	725	1360

Banyaknya pola mewakili banyaknya bulan dalam setahun.

Pola data real ditransformasi dengan menggunakan rumus (1) menjadi nilai yang berada pada range 0,1 hingga 0,9 seperti pada tabel 3.

Tabel 3. Pola data tranformasi pelatihan jaringan

POLA	INPUT			Target
	selisih	Halangan	Lwt Wkt	
1	0,4449	0,2879	0,6822	0,1623
2	0,9000	0,6697	0,4957	0,1000
3	0,6965	0,5606	0,1000	0,4826
4	0,7850	0,6939	0,2694	0,2507
5	0,3579	0,5000	0,3690	0,2420
6	0,6173	0,3061	0,1043	0,4681
7	0,6173	0,7788	0,3861	0,9000
8	0,2926	0,1182	0,4075	0,5725
9	0,2491	0,9000	0,6836	0,8420
10	0,4371	0,1000	0,9000	0,7623
11	0,1000	0,6333	0,7690	0,6957
12	0,2522	0,4879	0,8345	0,5942

#### d. Pelatihan

Pelatihan pertama adalah menambah node pada lapisan tersembunyi. Optimasi pembelajaran akan mengacu pada MSE terkecil, dan epoch paling sedikit. Hasil pelatihan terhadap penambahan node dalam lapisan tersembunyi terlihat pada tabel 4.

Tabel 4. Hasil Pelatihan dengan penambahan node

Jaringan	MSE	Epoch
3-1-1	0.00398	10406
3-2-1	0.00622	8555
3-3-1	0.00248	2725
3-4-1	7.88e-31	176
3-5-1	1.54e-32	22
3-10-1	6.16e-33	19
3-20-1	1.95e-32	39
3-30-1	5.14e-33	11
3-40-1	4.11e-33	13
3-50-1	1.75e-32	30
3-75-1	2.16e-32	606
3-100-1	1.95e-32	856

Dengan menggunakan jaringan 3-30-1 pelatihan selanjutnya adalah penggunaan learning rate dari 0.1-0.9 yang dapat dilihat pada tabel 5.

Tabel 5. Pengujian Learning Rate

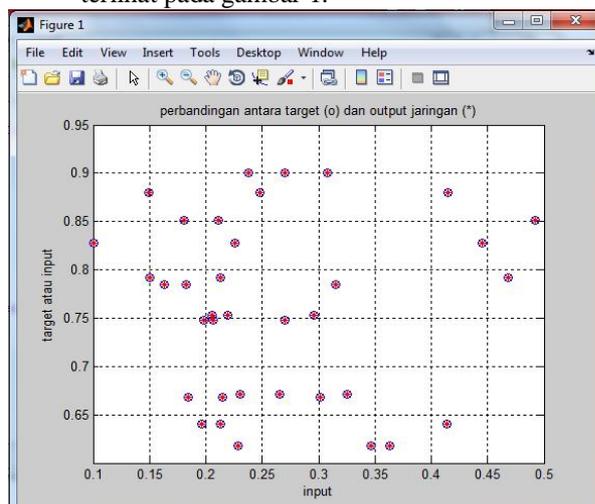
Learning rate	MSE	Epoch
0.1	5.14e-33	14
0.2	8.22e-33	10
0.3	9.24e-33	14
0.4	6.16e-33	13
0.5	4.11e-33	13
0.6	5.14e-33	10
0.7	6.16e-33	20
0.8	9.24e-33	27
0.9	9.24e-33	33

Pada penelitian ini hasil pelatihan yang paling optimal diambil berdasarkan MSE terkecil dan nilai epoch terkecil.

#### e. Hasil pelatihan

Setelah rangkaian pelatihan untuk mendapatkan jumlah node pada lapisan tersembunyi dan rearning rate yang akan menghasilkan error paling minimal maka, dapat dikatakan bahwa 30 node dan lerning rate 0.6 akan menghasilkan error paling minimal dengan jumlah epoch terkecil (waktu komputasi tercepat).

Hasil komputasi dengan menggunakan informasi diatas, telah menghasilkan pelatihan yang baik dengan dihasilkan error yang sangat kecil sehingga hasil pelatihan dengan target yang diharapkan sangat sesuai seperti yang terlihat pada gambar 1.



Gambar 2. Hasil jaringan (\*) dan target (o)

Pada gambar 2., menunjukkan bahwa hasil jaringan (\*) telah menempati posisi target (o), sehingga dapat dikatakan bahwa pelatihan yang

dikakukan telah berhasil karena hasil pelatihan telah sama dengan target yang diharapkan.

#### 4. PEMBAHASAN

Dengan menggunakan data kehadiran tahun 2011, kita akan mencoba memprediksi kehadiran tahun 2012. Walau pun tahun 2012 telah berjalan hampir separuh tahun, simulasi akan dilakukan untuk seluruh bulan pada tahun 2012, sehingga untuk bulan pada tahun 2012 yang telah ada data kehadirannya dapat digunakan untuk membandingkan hasil prediksi dan bulan yang belum terlewati pada tahun 2012, hasil simulasi ini dapat digunakan untuk memprediksi kehadiran pada bulan-bulan tersebut.

Data real akan digunakan untuk simulasi dapat terlihat pada tabel 6.

Tabel 6. Data real

selisih	Halangan	Lwt Wkt
2	161	691
109	127	768
141	107	524
160	289	502
128	133	664
190	201	440
384	225	118
64	270	299
573	249	134
538	310	128
488	165	319
440	265	289

Nilai-nilai pada tabel 6 akan ditransformasi terlebih dahulu sebelum dilakukan simulasi seperti pada tabel 7.

Tabel 7. Data transformasi

Selisih	Halangan	Lwt Wkt
0,1000	0,3128	0,8052
0,2499	0,1788	0,9000
0,2947	0,1000	0,5997
0,3214	0,8172	0,5726
0,2765	0,2025	0,7720
0,3634	0,4704	0,4963
0,6352	0,5650	0,1000
0,1869	0,7424	0,3228
0,9000	0,6596	0,1197
0,8510	0,9000	0,1123
0,7809	0,3286	0,3474
0,7137	0,7227	0,3105

Dengn hasil simulasi menggunakan jaringan yang telah dilatih akan meghasilkan prediksi kehadiran yang telah ditransformasikan kembali ke data real dengan rumus (2), seperti pada tabel 8.

Tabel 8. Hasil simulasi prediksi kehadiran tahun 2012

Bulan	Transformsi	Real
Januari	0,7341	1457
Februari	0,6202	1378
Maret	0,7894	1495

April	0,8237	1518
Mei	0,5490	1329
Juni	0,1655	1064
Juli	0,6746	1415
Agustus	0,8708	1551
September	0,1336	1042
Oktober	0,7699	1481
November	0,2734	1139
Desember	0,5916	1358

Pada saat penelitian ini dibuat telah diperoleh data kehadiran pada 6 bulan pertama (januari-juni 2012), sehingga dapat dilakukan perbandingan antara data prediksi dan data real yang ada pada 6 bulan. Selisih atau jarak antara prediksi dan data real tersaji pada tabel 9.

Tabel 9. Perbandingan data prediksi dan data real

Bulan	Real	Prediksi	Jarak
Januari	1654	1457	197
Februari	1199	1378	179
Maret	1387	1495	108
April	1307	1518	211
Mei	1290	1329	39
Juni	1358	1064	294

Jarak antara khadiran real dan prediksi, dari 6 bulan yang ada hanya bulan mei yang jaraknya berada dibawah 100, namun secara prediksi keuangan, dana yang disediakan tidak terlalu jauh berbeda, sehingga apabila ditotal dengan pembiayaan atara prediksi dan real maka perbedaan dana yang dikeluarkan tidak berselisih jauh

Sehingga apabila akan memprediksi alokasi dana intensif kehadiran tiap bulan atau sepanjang tahun 2012 dapat dilihat pada tabel 10.

Tabel 10. Prediksi alokasi dana intensif tahun 2012

Bulan	Kehadiran	Intensif
Januari	1457	Rp 58.260
Februari	1378	Rp 55.116
Maret	1495	Rp 59.788
April	1518	Rp 60.732
Mei	1329	Rp 53.152
Juni	1064	Rp 42.567
Juli	1415	Rp 56.619
Agustus	1551	Rp 62.035
September	1042	Rp 41.686
Oktober	1481	Rp 59.249
November	1139	Rp 45.545
Desember	1358	Rp 54.328
Total		Rp 649.083

Jika intensif kehadiran perbulan masih menggunakan Rp 40.000,- perhari maka dalam setahun alokasi dana yang diperlukan adalah Rp. 649.840.000 (enam ratus empat puluh sembilan juta delapan ratus empat puluh ribu) tentu dana yang cukup besar yang perlu perencanaan dan pengalokasian yang bijaksana.

## 5. Kesimpulan dan Saran

Memprediksi kehadiran untuk alokasi dana intensif kehadiran diperlukan untuk efisiensi dan efektifitas pendanaan pada suatu lembaga terutama lembaga swasta yang keuangannya sangat tergantung pada sumbangan masyarakat agar dapat mengalokasikan pos-pos dana dengan bijak dan terkontrol.

Tingkat kemiripan prediksi sangat tergantung pada data dan insiasi awal jaringan dan pemilihan node lapisan tersembunyi dalam jaringan, sehingga perlu diuji coba terus untuk mendapatkan hasil yang paling optimal.

Dengan perbandingan data kehadiran yang real dan prediksi, maka diperlukan input jaringan yang lebih banyak untuk dapat membentuk bobot jaringan yang paling optimal sehingga dapat menghasilkan jarak yang lebih kecil antara hasil prediksi dan data real.

Perlu juga dilakukan pembelajaran maupun simulasi terhadap jaringan dengan menambahkan waktu masuk dan keluar pegawai sebagai parameter kebiasaan pegawai pada pencatatan kehadirannya dan prediksi penambahan pegawai yang bisa perbulan, triwulan, semester maupun pertahun untuk mendapatkan hasil yang lebih akurat dalam prediksi nantinya.

Langkah lain yang dapat dilakukan untuk pelatihan jaringan untuk mendapatkan bobot yang optimal adalah melakukan pelatihan jaringan dengan data input dan target yang terbaru, hal ini berhubungan dengan trend kebiasaan yang berubah yang bisa saja disebabkan oleh perubahan peraturan atau penambahan atau pengurangan pegawai, untuk itu perlu dilakukan penelitian terseniri untuk itu.

## Daftar Pustaka

- [1]. Dayhoff, Judith E., 1990, "Neural Network Architektur (An Introduction)", USA: Van Nostrand Reinhold.
- [2]. Demuth, Howard And Mark Beale, 2001 , "Neural Network Toolbox For Use With Matlab". The Mathwork.
- [3]. Fausett, L., 1994, "Fundamentals of Neural Network: Architectures, Algorithms, and Applications", Prentice-Hall, Inc., New Jersey.
- [4]. Haykin, S., 1994, "Neural Network, A Comprehensive Foundation", Prentice Hall
- [5]. Jong, J.S., 1992, "Application Of Back Propagation Method In Forecasting Problem", Master Thesis In Asian Institute Of Technology.
- [6]. Karray, Fakhreddine O. And a, Clarence De Silva, 2004, "Soft Koputing And Intelligent Systems Design-Theory, Tools And Application", Addison Wesley
- [7]. Russel, Stuart And Peter Norving, 2003, "Artificial Intelligence A Modern Approach", Prentice Hall, 2nd Edition
- [8]. Yildiz, B., 2001, "Use of Artificial Neural Networks in Prediction of Financial Failures (Turkish)", Journal of IMKB, Vol.5, No.17.

