
PERBANDINGAN ANTARA METODE *BAYESIAN-BACKPROPAGATION* DAN *GENETIC-BACKPROPAGATION* PADA PREDIKSI JUMLAH PENGANGGURAN TERBUKA DI INDONESIA

Dian Eka Ratnawati, Dyva Pandhu Adwandha¹, Yure Firdaus Arifin², dan Machsus

Fakultas Ilmu Komputer, Universitas Brawijaya
Jln Veteran, Malang, Jawa Timur 65145
⁴Fakultas Vokasi, ITS
Jalan Raya ITS, Sukolilo, Surabaya, Jawa Timur 60111
E-mail: dian_ilkom@ub.ac.id

ABSTRAK

Metode backpropagation merupakan metode yang bagus dipergunakan untuk melakukan prediksi. Bobot adalah hal penting pada metode backpropagation. Bobot awal yang dilakukan secara random memungkinkan iterasi yang lama dan hasil yang belum tentu bagus, sehingga perlu dilakukan optimasi. Beberapa metode optimasi dipakai untuk memperbaiki metode ini. Pada penelitian ini akan melakukan optimasi pada metode backpropagation ini dengan menggunakan Algoritma Genetik dan Bayesian. Hal ini karena kehandalan dan kesederhanaan dari kedua metode tersebut.

Pada metode genetic- backpropagation, algoritma genetik dipergunakan untuk mencari bobot awal dan bias yang optimal. Ukuran optimal ini adalah bobot yang menghasilkan nilai MSE yang kecil, MSE dipergunakan sebagai nilai fitnessnya. Pada bayesian-backpropagation, melakukan optimasi nilai bobot dan bias awal dengan menggunakan metode Bayesian yang sudah dimodifikasi dari Kalman Filter.

Hasil ujicoba dari nilai Average Forecast Error Rate (AFER) menunjukkan bahwa Bayesian-backpropagation tidak selalu lebih unggul dari genetic-based backpropagation dalam melakukan prediksi jumlah pengangguran terbuka, begitu juga sebaliknya. Hal ini tergantung dari jumlah pola (jumlah data time series) yang dipergunakan untuk melakukan peramalan. Tetapi kedua metode tersebut selalu lebih baik dari metode backpropagation.

Kata kunci: *backpropagation, bayesian-backpropagation, genetic- backpropagation, Kalman Filter, pengangguran terbuka*

PENDAHULUAN

Prediksi merupakan proses perkiraan yang sistematis untuk diproyeksikan ke dalam suatu nilai menggunakan persamaan matematika dan statistika berdasarkan data di masa lalu dan masa sekarang, sehingga data hasil prediksi dapat mendekati hasil nyata. (Dewi, 2016). Terdapat dua teknik dalam memprediksi yaitu teknik prediksi kualitatif dan kuantitatif. Yang akan dipergunakan pada penelitian kali ini adalah kuantitatif karena hasilnya berdasarkan metode yang dipergunakan dalam prediksi tersebut (Berutu, 2013). Metode yang dapat diimplementasikan untuk prediksi salah satunya adalah jaringan saraf tiruan *backpropagation*, karena metode tersebut mampu mempelajari pola dalam *dataset time-series*. Hasil dari beberapa penelitian sebelumnya yang menggunakan metode backpropagation bagus, hanya saja melihat kelemahan yang ada pada metode tersebut yang penentuan bobot awalnya dilakukan secara random, maka beberapa Peneliti sebelumnya sudah melakukan optimasi. Beberapa metode optimasi yang dipergunakan antara lain Algoritma Genetik dan Bayesian.

Kombinasi *backpropagation* dengan algoritma genetika dikenal dengan *genetic-based backpropagation*. Salah satu penelitian yang menerapkan metode *genetic-based backpropagation*

adalah prediksi mengenai aktifitas lalu lintas jaringan (Haviluddin & Alfred, 2015). Dalam penelitian tersebut, algoritma genetika dipakai untuk mengoptimasi bobot dan *thresholds*. Peneliti membandingkan metode *backpropagation* dengan *genetic-based backpropagation* dalam memprediksi aktifitas lalu lintas jaringan. Kemampuan metode tersebut diukur menggunakan analisis statistik yang dinamakan *Mean of Square Error* (MSE). Semakin kecil nilai MSE, maka semakin baik hasil perhitungan dari metode yang dipakai. Hasil nilai MSE terbaik yang didapatkan dari kedua metode tersebut berturut-turut adalah 0,009636 dan 0,000565. Dari hasil MSE yang diperoleh, dapat diketahui bahwa metode *genetic-based backpropagation* memiliki hasil yang baik dalam kasus prediksi.

Sedangkan kombinasi *backpropagation* dengan bayesian dikenal dengan *bayesian- backpropagation* Pada penelitian sebelumnya yang telah dilakukan oleh Nadir Murru dan Rosaria Rossini yaitu menerapkan metode *Bayesian* untuk inialisasi bobot pada algoritma *Backpropagation* untuk pengenalan karakter. Dari hasil penelitian yang dilakukan oleh Nadir Murru dan Rosaria Rossini tersebut membuktikan bahwa metode gabungan *Bayesian Weights Initialization* dan *Backpropagation* menghasilkan tingkat akurasi yang lebih tinggi dibandingkan dengan metode *random initialization* (Murru & Rossini, 2016)

Dari kedua penelitian sebelumnya menunjukkan bahwa adanya tambahan metode optimasi yakni genetic atau Bayesian menghasilkan akurasi yang lebih baik daripada tanpa adanya optimasi. Pada penelitian ini mencoba membandingkan kedua metode tersebut dalam kemampuannya untuk memprediksi jumlah pengangguran terbuka di Indonesia. Hal ini dikarenakan jumlah pengangguran terbuka yang berubah dari tahun ke tahun kadang mengalami penurunan ataupun peningkatan. Dengan adanya prediksi jumlah pengangguran, diharapkan dapat membantu pemerintah dan pihak terkait untuk mengambil kebijakan yang tepat serta tindakan preventif dalam menanggulangi permasalahan tersebut.

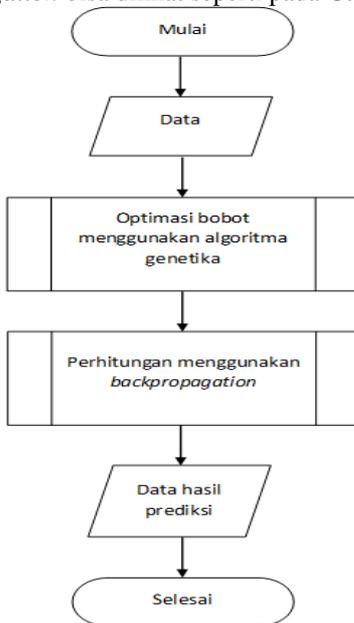
METODE PENELITIAN

1. Data

Data yang dipakai dalam penelitian ini merupakan data sekunder yang diperoleh dari Badan Pusat Statistik. Pengumpulan data dilakukan dengan cara mencatat jumlah pengangguran terbuka di Indonesia dari survei yang dilakukan oleh Survei Angkatan Kerja Nasional (Sakernas) mulai tahun 1986 sampai tahun 2016. Pada tahun 2005 sampai tahun 2016 survei dilakukan sebanyak dua kali setiap tahun yaitu pada bulan Februari dan bulan Agustus.

2. Metode *genetic-based backpropagation*

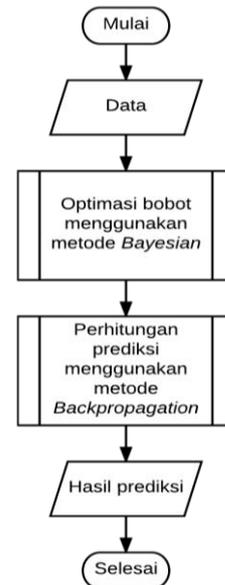
Diagram Alir dari metode *genetic-based backpropagation* bisa dilihat seperti pada Gambar 1.



Gambar 1. Diagram Alir Sistem *genetic-based backpropagation*

3. Metode *bayesian-based backpropagation*

Diagram Alir dari metode *Bayesian backpropagation* bisa dilihat seperti pada Gambar 2



Gambar 2. Diagram Alir Sistem *bayesian-based backpropagation*

Tahapan-tahapan baik pada metode *Genetic-backpropagation* dan *Bayesian-Backpropagation* yang ada pada Gambar 1 dan 2 adalah :

Memasukkan data jumlah pengangguran terbuka dari *database* yang dipilih oleh pengguna untuk melakukan prediksi.

Pada Gambar 1, bobot dan bias w yang paling optimal akan dicari dengan menggunakan algoritma genetic, sedangkan pada Gambar 2 bobot dan bias dicari dengan menggunakan algoritma *Bayesian*

Setelah bobot optimal ditemukan maka hasil pada langkah ke-2 tersebut digunakan sebagai masukan untuk melakukan proses prediksi menggunakan algoritma *Backpropagation*.

Setelah proses pada langkah ke-3 selesai, sistem akan menampilkan hasil dari prediksi beserta hasil *MSE*.

HASIL DAN PEMBAHASAN

Pengujian Perbandingan Hasil Prediksi metode *Backpropagation* dan *Genetic-backpropagation*

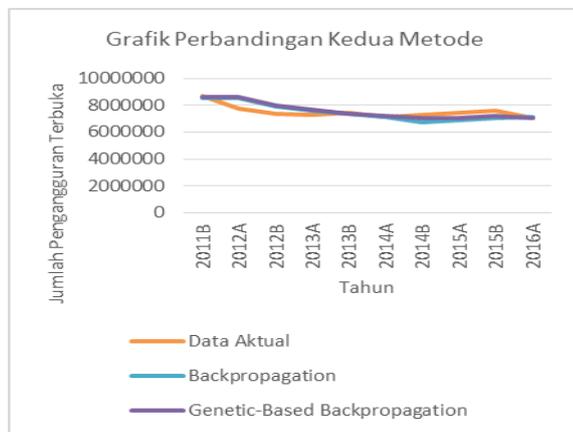
Pengujian ini bertujuan untuk membandingkan hasil prediksi yang diperoleh menggunakan metode *backpropagation* dan *genetic-based backpropagation* dengan menggunakan nilai AFER yang diperoleh dan waktu yang digunakan untuk melakukan proses training oleh kedua metode. Pada pengujian ini dilakukan 10 kali uji coba untuk memprediksi jumlah pengangguran terbuka dari tahun 2011B sampai 2016A. Parameter *backpropagation* yang digunakan yaitu jumlah pola sebesar 10, 20000 iterasi dan nilai α 0,1 Hasil uji coba 1 sampai 10 ditunjukkan pada Tabel 1, Tabel 2 dan Gambar 3.

Tabel 1. Hasil Percobaan Metode *Backpropagation*

Uji oba	Tahun	Jumlah	<i>Backpropagation</i>		
			Hasil Prediksi	Waktu (detik)	AFER (%)
1	2011B	8681392	8494537	16,575	0.021997079
2	2012A	7757831	8486746	16,675	0.085888632
3	2012B	7344866	7882257	16,630	0.0681773
4	2013A	7240897	7628427	16,634	0.050800775
5	2013B	7410931	7336481	16,648	0.010147917
6	2014A	7147069	7109857	16,662	0.005233861
7	2014B	7244905	6771203	16,620	0.069958322
8	2015A	7454767	6915428	16,738	0.07799069
9	2015B	7560822	7081447	16,884	0.067694498
10	2016A	7024172	7121240	16,757	0.013630772
Rata-rata				16,682	4.715198444

Tabel 2 Hasil Percobaan Metode Genetic-Based *Backpropagation*

Uji oba	Tahun	Jumlah	<i>Genetic-Based Backpropagation</i>		
			Hasil Prediksi	Waktu (detik)	AFER (%)
1	2011B	8681392	8619285	16,892	0.007205586
2	2012A	7757831	8614065	16,772	0.099399529
3	2012B	7344866	8001856	16,925	0.082104702
4	2013A	7240897	7641588	16,873	0.052435567
5	2013B	7410931	7349169	16,883	0.008403943
6	2014A	7147069	7198107	16,895	0.007090475
7	2014B	7244905	7073538	16,922	0.02422649
8	2015A	7454767	7046428	16,935	0.057949787
9	2015B	7560822	7208109	16,959	0.048932806
10	2016A	7024172	7024190	16,916	2.56257E-06
Rata-rata				16,897	3.877514478



Gambar 3 Grafik Perbandingan Hasil Prediksi

Dari Tabel 1 dan 2 diketahui bahwa metode *genetic-based backpropagation* memperoleh rata-rata nilai AFER 3.88%, sedangkan metode *backpropagation* mempunyai rata-rata AFER : 4.71%. Jadi adanya optimasi dengan algoritma genetic tersebut memperkecil nilai AFER. Berkurangnya nilai AFER ini disebabkan karena dalam penentuan bobot dan bias w pada metode *backpropagation* dilakukan secara acak, sedangkan pada metode *genetic-based backpropagation* bobot dan bias w akan dicari yang paling optimal sebelum diproses. Namun waktu yang dibutuhkan metode *genetic-based backpropagation* untuk proses *training* sedikit lebih lama karena adanya proses optimasi bobot dan bias.

Pengujian Perbandingan Hasil Prediksi metode *Backpropagation* dan Bayesian -*backpropagation*

Pengujian ini bertujuan untuk mengetahui pengaruh jumlah iterasi serta membandingkan kecepatan dan tingkat akurasi sistem antara inialisasi bobot secara *random* dengan inialisasi *Bayesian*. Hasil perbandingan waktu diambil pada saat *training* sedangkan *AFER* diambil pada saat *testing*. Nilai variabel yang digunakan dalam pengujian ini adalah $\alpha = 0.7$, $t_{max} = 2$, dan jumlah pola data = 15. Data yang digunakan untuk *training* adalah tahun 2008b sampai 2015b sedangkan untuk tahun prediksi adalah 2016a. Hasil pengujian ditunjukkan pada Tabel 3, Tabel 4 serta grafik pada Gambar 4.

Tabel 3 Hasil pengujian inialisasi Random

Jumlah Iterasi	<i>Random</i>	
	Waktu (milidetik)	AFER (%)
1000	609	4,2596
2000	1266	3,2063
5000	3078	2,6209
10000	6141	2,5793
15000	9156	2,7336
20000	12266	2,9056
50000	30813	3,5636
75000	45937	3,8270
100000	61125	4,0144

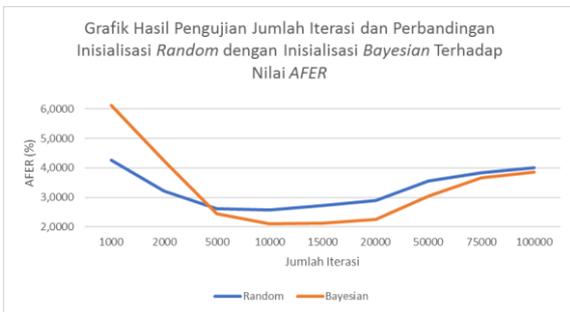
Tabel 4 Hasil pengujian inialisasi Bayesian

Jumlah Iterasi	<i>Bayesian</i>	
	Waktu (milidetik)	AFER (%)
1000	703	6,1292
2000	1719	4,2450
5000	4234	2,4509
10000	7516	2,1003
15000	9250	2,1197
20000	15438	2,2448
50000	37312	3,0517
75000	46094	3,6718
100000	76828	3,8609



Gambar 4 Grafik hasil pengujian perbandingan waktu komputasi antara inisialisasi random dengan inisialisasi Bayesian

Berdasarkan Gambar 4 menunjukkan bahwa baik dengan menggunakan inisialisasi random maupun Bayesian terlihat bahwa semakin besar jumlah iterasi maka waktu proses training akan semakin besar. Tetapi selisih waktu proses training pada sistem antara inisialisasi random dengan inisialisasi menggunakan metode Bayesian sangat kecil.



Gambar 5 Grafik hasil pengujian perbandingan inisialisasi random dengan inisialisasi Bayesian terhadap nilai AFER

Berdasarkan hasil pengujian pada Gambar 5 menunjukkan bahwa hasil prediksi dengan jumlah iterasi dibawah 5000 dengan inisialisasi *random* nilai AFER lebih kecil daripada inisialisasi *Bayesian*, tetapi pada iterasi di atas 5000 inisialisasi *Bayesian* nilai AFER nya lebih kecil. Hal tersebut terjadi karena nilai inisialisasi bobot *random* lebih besar daripada inisialisasi *Bayesian* sehingga proses pelatihan inisialisasi *random* lebih cepat, tetapi tingkat ketelitian inisialisasi *Bayesian* lebih tinggi dan memerlukan jumlah iterasi yang lebih banyak untuk mencapai hasil optimal.

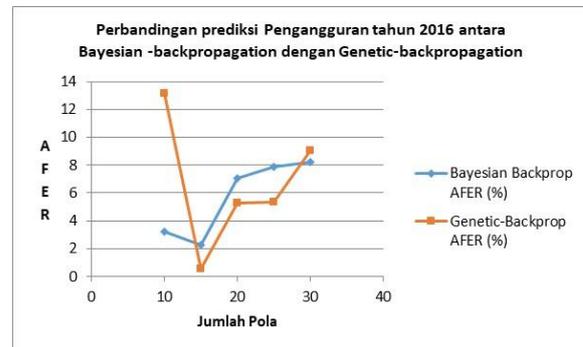
Pengujian Perbandingan Hasil Prediksi metode Genetic-Backpropagation dan Bayesian - backpropagation

Pengujian ini bertujuan untuk mengetahui perbandingan antara metode *genetic-backpropagation* dan *bayesian-backpropagation* dalam memprediksi jumlah pengangguran pada tahun 2016. Pada prediksi yang dilakukan ini dilakukan beberapa kali dengan menggunakan jumlah pola yang berbeda yaitu 10,15,20,25 dan 30. Jumlah pola data adalah banyaknya data dari tahun sebelumnya yang dipergunakan, semakin besar jumlah pola berarti semakin banyak data sebelumnya yang dipergunakan. Sedangkan parameter yang dipergunakan adalah jumlah iterasi 20000 dengan nilai alpha 0.7. Hasil

pengujian ditunjukkan pada Tabel 5 serta grafik pada Gambar 6

Tabel 5 Hasil pengujian inisialisasi Bayesian

Pola Data	Bayesian Backprop	Genetic-Backprop
	AFER (%)	AFER (%)
10	3.2216	13.1738
15	2.2448	0.5419
20	7.0553	5.2761
25	7.8518	5.3586
30	8.2191	9.0299
Rata-rata	5.71852	6.67606



Gambar 6. Grafik hasil pengujian perbandingan prediksi antara genetic-backpropagation dan bayesian-backpropagation

Berdasarkan Tabel 5 dan Gambar 6 menunjukkan bahwa secara rata-rata dengan menggunakan jumlah pola yang berbeda, inisialisasi dengan Bayesian lebih unggul daripada dengan menggunakan Algoritma Genetik. Tetapi dengan jumlah pola > 10 secara rata-rata genetic lebih baik daripada . Berarti dengan jumlah pola yang sedikit Bayesian lebih cocok dipergunakan, sebaliknya dengan jumlah pola yang banyak Algoritma Genetik lebih cocok. Jumlah pola >10 menunjukkan bahwa semakin banyak pola yang dipergunakan akan menghasilkan nilai AFER yang semakin besar atau hasil prediksi yang kurang bagus.

KESIMPULAN

Berdasarkan hasil dari penelitian yang telah dilakukan tentang sistem prediksi jumlah pengangguran terbuka di Indonesia menggunakan gabungan metode *Bayesian* dan *Backpropagation*, dapat diambil kesimpulan sebagai berikut:

Sistem prediksi jumlah pengangguran terbuka di Indonesia dapat diimplementasikan menggunakan metode *Bayesian-Backpropagation* dan *Genetik-Backpropagation*.. Untuk *Bayesian-Backpropagation* yang pertama adalah inisialisasi bobot menggunakan metode *Bayesian* yang merupakan modifikasi *Kalman filter*. Setelah diperoleh bobot untuk inisialisasi maka dilakukan proses *training*. Dari proses *training* akan mendapatkan bobot optimum, bobot tersebut digunakan untuk memprediksi dengan cara menerapkan tahap propagasi maju (*Feedforward*). Sedangkan metode *genetic-based backpropagation*

sama seperti yang dilakukan pada *Bayesian-Backpropagation* hanya saja optimasi bobot dan biasanya dilakukan menggunakan algoritma genetika.

Berdasarkan hasil pengujian yang telah dilakukan bahwa adanya optimasi pada inialisasi bobot awal baik dengan menggunakan algoritma genetika maupun Bayesian mempunyai nilai AFER yang lebih kecil atau hasil prediksi yang lebih baik. Secara waktu komputasi adanya penambahan Algoritma Genetik maupun Bayesian tersebut waktu komputasi yang diperlukan saat proses training lebih besar meskipun tidak terlalu banyak selisihnya.

Perbandingan kedua metode tersebut dalam melakukan prediksi secara rata-rata Bayesian lebih bagus, tetapi ada saatnya Algoritma Genetik lebih bagus dengan jumlah pola yang tidak terlalu sedikit atau tidak terlalu banyak

REFERENSI

- Adwandha, D., Ratnawati, D., & Adikara, P. Prediksi Jumlah Pengangguran Terbuka di Indonesia menggunakan Metode Genetic-Based Backpropagation. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 1, no. 4, p. 341-351, mei 2017. ISSN 2548-964X. Tersedia pada: <<http://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/108>>. Tanggal Akses: 07 Juli 2017
- Arifin, Y., Ratnawati, D., & Adikara, P. Implementasi Gabungan Metode Bayesian dan Backpropagation untuk Peramalan Jumlah Pengangguran Terbuka di Indonesia. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 1, no. 4, p. 330-340, mei 2017. ISSN 2548-964X. Tersedia pada: <<http://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/109>>. Tanggal Akses: 07 Juli 2017
- Badan Pusat Statistik. (2015). Keadaan Ketenagakerjaan Agustus 2015.
- Fausett, L. (1994). *Fundamentals of Neural Networks* (Prentice-H). Prentice-Hall.
- Haviluddin, & Alfred, R. (2015). A Genetic-Based Backpropagation Neural Network for Forecasting in Time-Series Data (p. 6). IEEE. <https://doi.org/10.1109/ICSITech.2015.7407796>
- Masduqi, A., & Apriliani, E. (2008). Estimation of Surabaya River Water Quality Using Kalman Filter Algorithm. *IPTEK, The Journal for Technology and Science*, 19(3), 87–91.
- Murru, N., & Rossini, R. (2016). Neurocomputing A Bayesian approach for initialization of weights in backpropagation neural net with application to character recognition. *Neurocomputing*, 193, 92–105. <https://doi.org/10.1016/j.neucom.2016.01.063>
- Palega, O., Wardoyo, S., & Wiryadinata, R. (2013). Estimasi Kecepatan Kendaraan Menggunakan Kalman Filter. *SETRUM*, 2(2), 60–65.
- Soomlek, C., Kaewchainam, N., Simano, T., & So-In, C. (2016). Using backpropagation neural networks for flood forecasting in PhraNakhon Si Ayutthaya, Thailand. *ICSEC 2015 - 19th International Computer Science and Engineering Conference: Hybrid Cloud Computing: A New Approach for Big Data Era*. <https://doi.org/10.1109/ICSEC.2015.7401424>
- Syukriyawati, G. (2015). Implementasi Metode Average-Based Fuzzy Time Series Models pada Prediksi Jumlah Penduduk Provinsi DKI Jakarta. Brawijaya University.
- Welch, G., & Bishop, G. (2006). An Introduction to the Kalman Filter. *Department of Computer Science University of North Carolina at Chapel Hill*, 1–16.