

ANALISIS BACKPROPAGATION DENGAN RESILIENT PROPAGATION ARTIFICIAL NEURAL NETWORK DALAM PENENTUAN BERAT BADAN KAMBING

Max Teja Ajie Cipta W., Teknik Informatika Sekolah Tinggi Teknik PLN, max@sttpln.ac.id

Dian Hartanti, Teknik Informatika Sekolah Tinggi Teknik PLN, dhianiez.smart9@gmail.com

Abstrak

Penentuan berat badan hewan ternak berdasarkan ukuran tubuh diperlukan ketika penimbangan langsung tidak praktis atau ketika alat timbang tidak tersedia. Teknik ini dapat digunakan untuk mendeteksi berat badan yang tidak wajar misalnya akibat pemberian pakan sebelum ditimbang. Dalam penelitian ini, penentuan berat badan hewan ternak berdasarkan ukuran tubuh dilakukan terhadap kambing Kacang betina dengan pendekatan kecerdasan buatan, yaitu dengan menggunakan Resilient Propagation (RPROP) Neural Network. Sebagai pembandingan, percobaan juga dilakukan dengan metode Backpropagation (BP) dan RPROP tanpa optimasi bobot awal. Hasilnya RPROP tanpa optimasi bobot awal dapat menghasilkan model dengan nilai MSE yang lebih baik antara 1,90% - 2,71% dibanding metode training BP yang juga tanpa optimasi bobot awal. Penerapan optimasi bobot awal menggunakan ABC terhadap metode training RPROP dapat menghasilkan nilai MSE yang lebih baik antara 0,14% - 3,03% dibanding metode training RPROP bobot awal acak.

Kata Kunci: berat badan, kambing Kacang betina, *artificial neural network*, *backpropagation*, *resilient propagation*, *artificial bee colony*, optimasi bobot awal, variabel independent.

PENDAHULUAN

Kambing Kacang merupakan kambing asli Indonesia. Populasi terbesar kambing ini berada di pulau Jawa. Keistimewaan kambing Kacang adalah merupakan kambing potong yang sangat prolif (sering melahirkan anak kembar) dan mampu memanfaatkan hijauan dengan kualitas jelek dengan menampilkan tingkat pertumbuhan yang baik sehingga dapat dikembangkan di daerah yang gersang (Budisatria, 2009). Oleh karena itu, kambing ini sangat cocok dengan iklim Indonesia yang sering dilanda musim kemarau berkepanjangan. Selain itu, sifatnya yang sangat prolif dapat menguntungkan peternak, terutama yang bergerak di bidang pengembangbiakan.

Kambing betina memegang peranan penting dalam usaha peningkatan populasi kambing ternak. Untuk perkawinan secara kelompok, satu ekor kambing jantan dapat dipasangkan dengan 10 hingga 20 ekor kambing betina (Sutama, 2009). Dengan demikian, peningkatan populasi kambing ternak dapat dilakukan secara efisien. Lebih lanjut, jika kambing yang dikembangkan sering menghasilkan dua atau tiga ekor anak kembar, maka peningkatan populasi dapat dilakukan dengan lebih

cepat.

Teknik penentuan berat badan hewan ternak berdasarkan ukuran tubuh biasa digunakan dalam peternakan modern ketika penimbangan langsung tidak praktis atau alat timbang tidak tersedia. Keunggulan teknik ini dibanding penimbangan langsung adalah teknik ini dapat digunakan untuk mendeteksi berat badan tidak wajar karena kecurangan pedagang, misalnya ketika kambing diberi makan sebelum ditimbang. Hal ini dikarenakan ukuran tubuh yang biasa digunakan untuk penentuan berat badan tidak dipengaruhi oleh isi perut hewan ternak. Hasil penentuan berat badan dapat digunakan untuk penentuan porsi pakan, penentuan dosis obat, dan untuk menjaga agar pertumbuhan dan peningkatan berat badan hewan ternak tetap ideal, serta untuk penentuan harga jual.

Teknik *data mining* dengan *Artificial Neural Network* (ANN) mempunyai beberapa kelebihan dibanding teknik *data mining* lainnya. Teknik ini dapat digunakan untuk memecahkan masalah yang tidak dapat dipecahkan dengan cara tradisional (Wang, 2011). ANN memiliki kinerja yang kuat dalam menangani pola masukan yang berisik atau tidak lengkap, toleransi kesalahan yang tinggi, dan

kemampuan untuk menggeneralisasi dari input data (Shi, 2012).

Dalam penelitian ini, penentuan berat badan hewan ternak berdasarkan ukuran tubuh dilakukan terhadap kambing Kacang betina dengan pendekatan kecerdasan buatan, yaitu dengan *Resilient Propagation (RPROP) Neural Network*.

Dalam pembuatan model penentuan berat badan kambing Kacang betina menggunakan ANN, terdapat beberapa hal yang perlu diperhatikan. Pertama adalah dalam hal preprocessing. Beberapa variabel independen memiliki nilai korelasi yang lebih tinggi dibanding variabel lainnya sehingga diperlukan seleksi fitur. ANN juga hanya dapat menerima input dan menghasilkan output dengan kisaran tertentu. Jadi, variabel-variabel yang telah melalui seleksi fitur juga perlu dinormalisasi nilainya. Kedua adalah dalam hal training ANN. Model yang dihasilkan oleh tiap sesi training antara sesi training yang satu dengan yang lain dapat bervariasi walaupun parameter yang digunakan sama persis. Ini diduga disebabkan oleh bobot awal ANN yang acak. Optimasi bobot awal diharapkan dapat menghasilkan model yang lebih konsisten sehingga didapatkan peningkatan kualitas model penentuan berat badan.

Tujuan utama penelitian ini adalah untuk menguji efektivitas optimasi bobot awal ANN terhadap model penentuan berat badan yang dihasilkan. Pengujian dilakukan dengan jumlah variabel independen yang bervariasi untuk mengetahui pengaruh jumlah variabel terhadap efektivitas optimasi bobot awal.

Penelitian ini bermanfaat untuk mendapatkan model penentuan berat badan kambing Kacang betina yang lebih baik. Selain itu, penelitian ini juga diharapkan dapat menjadi salah satu dasar untuk penelitian berikutnya terkait dengan optimasi bobot awal ANN dan pengaruh jumlah variabel independen terhadap efektivitas optimasi bobot awal ANN.

METODE PENELITIAN

Dataset

Tabel 1: Dataset ukuran tubuh dan berat badan kambing Kacang betina

Variabel	Min.	Maks.	Rata-rata	Satuan
Lingkar Dada	23,57	83,53	55,30	Cm
Lebar Dada	5,43	30	12,74	Cm
Dalam Dada	8,93	36	19,46	Cm
Panjang Badan	19,30	67,73	44,01	Cm

Tinggi Pundak	22,13	73	47,89	Cm
Tinggi Pinggul	24,03	74	50,25	Cm
Lebar Pinggul	4,4	25	13,36	Cm
Berat Badan	1,58	41,13	16,22	Kg

Dataset yang digunakan merupakan hasil pengukuran terhadap kambing Kacang betina di Grobogan dan Karanganyar, Jawa Tengah pada tahun 2015 oleh mahasiswa Fakultas Peternakan dan Pertanian UNDIP Semarang. Dataset ini berisi ukuran-ukuran tubuh dan berat badan 443 ekor kambing Kacang betina. Ukuran-ukuran tubuh tersebut meliputi lingkar dada, lebar dada, dalam dada, panjang badan, tinggi pundak, tinggi pinggul, dan lebar pinggul. Pada dataset ini, ukuran-ukuran tubuh adalah variabel independen, sedangkan berat badan adalah variabel dependen. Ukuran-ukuran tubuh seluruhnya menggunakan satuan centimeter (cm), sedangkan berat badan menggunakan satuan kilogram (kg).

Preprocessing

Pertama, seluruh variabel dalam dataset disamakan presisinya dengan dibulatkan hingga satu angka di belakang koma. Kemudian, data-data yang kembar dieliminasi hingga hanya menyisakan data-data yang unik di dalam dataset.

Selanjutnya, nilai korelasi tiap variabel independen terhadap berat badan dihitung dengan persamaan 1. Lalu, dipilih variabel-variabel independen dengan nilai korelasi paling besar.

Seluruh variabel independen yang terpilih beserta variabel dependen dinormalisasi agar nilainya masuk dalam kisaran yang dapat diterima oleh ANN sesuai fungsi aktivasi sigmoid. Metode normalisasi yang digunakan adalah metode normalisasi min-max dengan menggunakan persamaan 2.

Eksperimen

Model penentuan berat badan kambing Kacang betina berdasarkan ukuran tubuh menggunakan ANN dibuat lebih dahulu dengan metode *training* yang biasa digunakan, yaitu BP dengan bobot awal acak. Hasilnya digunakan sebagai *baseline*. Kemudian, percobaan dilanjutkan dengan metode *training* RPROP. Varian RPROP yang digunakan adalah iRPROP+.

Variabel-variabel independen yang digunakan untuk tiap metode *training* adalah variabel-variabel yang telah lolos seleksi fitur saja. Variabel-variabel tersebut digunakan secara bertahap mulai dari satu variabel, dua variabel, tiga variabel, dan

seterusnya dengan urutan mulai dari yang nilai korelasinya paling besar. Sebagai pembanding, percobaan juga dilakukan tanpa seleksi fitur, yaitu dengan menggunakan seluruh variabel independen yang ada di dalam dataset.

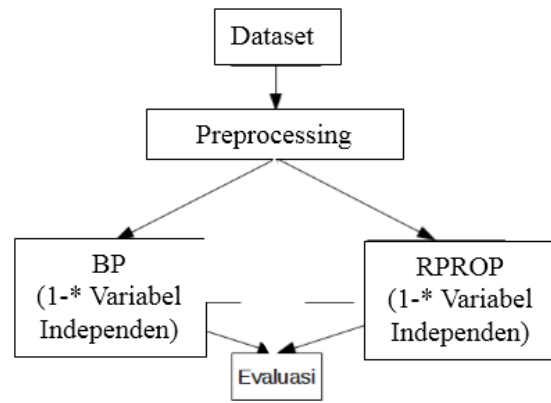
Alur percobaan secara keseluruhan dapat dilihat pada gambar 1. Daftar variasi kombinasi percobaan yang dilakukan selengkapnya ditunjukkan pada tabel 2.

Tabel 2: Kombinasi percobaan yang dilakukan


No.	Percobaan	Jumlah Variabel Independen	Keterangan
1.	BPROP	1-*	Bobot awal ANN acak
2.	RPROP	1-*	Bobot awal dengan optimasi ABC

Arsitektur ANN dalam penelitian ini dapat dilihat pada gambar 2. Arsitektur ANN yang digunakan mempunyai satu *hidden layer* dengan lima buah neuron. Penentuan *hidden layer* ini berdasarkan penelitian sebelumnya tentang prediksi berat badan kelinci Selandia Baru dengan ANN (Salawu, 2014). Jumlah neuron pada *input layer* mengikuti jumlah variabel yang digunakan. Pada *output layer* hanya terdapat satu neuron. Arsitektur ANN yang digunakan juga dilengkapi dengan bias pada *input layer* dan *hidden layer* untuk meningkatkan potensi pemodelan. Fungsi aktivasi yang digunakan pada seluruh neuron adalah sigmoid (persamaan 4). Parameter yang digunakan untuk metode *training* iRPROP+ adalah Target MSE 0,0001 dan Maximum Epoch 50000.

Untuk percobaan optimasi bobot awal ANN menggunakan ABC, pada awalnya bobot awal ANN dinisialisasi dengan acak, kemudian dioptimasi dengan fungsi *fitness* (persamaan 12). Yang dimaksud dengan MSE di sini adalah nilai MSE dari ANN yang digunakan saat menggunakan bobot yang diptimasi oleh ABC. Algoritma ABC dijalankan dengan parameter *lower bound* -5, *upper bound* 5, *colony size* 100 dan *MCN* 500. Setelah melalui proses ini, ANN di-*training* dengan iRPROP+.



Gambar 1: Alur percobaan



Gambar 2: Arsitektur ANN yang digunakan

$$f(x) = \frac{1}{MSE}$$

Evaluasi

Model yang dihasilkan oleh tiap metode percobaan dengan jumlah variabel independen yang bervariasi dibandingkan nilai MSE-nya. Namun, karena nilai MSE model yang dihasilkan tiap sesi training bervariasi, eksperimen diulang sebanyak 30 kali kemudian nilai rata-rata MSE-nya dihitung. Nilai rata-rata MSE dari tiap metode percobaan dibandingkan.

HASIL PENELITIAN

Preprocessing

Setelah melalui penyamaan presisi dengan pembulatan hingga satu angka di belakang koma, ditemukan 20 buah data kembar. Data-data kembar tersebut dieliminasi hingga hanya menyisakan data-data yang unik di dalam dataset. Dengan demikian, jumlah data yang lolos tahap ini adalah 423 buah. Perhitungan korelasi dilakukan terhadap 423 buah data yang telah lolos pada tahap sebelumnya. Hasilnya menunjukkan bahwa seluruh variabel independen dalam dataset mempunyai nilai korelasi

positif terhadap variabel dependen. Nilai korelasi terbesar adalah variabel lingkaran dada, sedangkan yang terkecil adalah variabel lebar dada (tabel 3).

Berdasarkan interpretasi nilai korelasinya, variabel-variabel independen dalam dataset ini terbagi menjadi dua kelompok, yaitu variabel yang korelasinya tinggi dan variabel yang korelasinya sangat tinggi. Dalam penelitian ini, dipilih satu kelompok saja, yaitu yang interpretasi korelasinya sangat tinggi. Variabel-variabel independen dalam kelompok tersebut adalah lingkaran dada, panjang badan, tinggi pinggul, dan tinggi pundak. Bersama dengan variabel dependen berat badan, keempat variabel independen yang lolos seleksi fitur ditunjukkan pada tabel 3..

Tabel 3.: Nilai korelasi tiap variabel independen

Variabel Independen	Nilai Korelasi	Interpretasi
Lingkar dada	0,9506133145	Korelasi positif sangat tinggi
Panjang badan	0,8992768031	
Tinggi pinggul	0,8759635254	
Tinggi pundak	0,8719850679	
Lebar pinggul	0,7614794777	Korelasi positif tinggi
Dalam dada	0,7570290469	
Lebar dada	0,650373101	

Tabel 4: Variabel independen dan dependen yang terpilih (sebelum normalisasi)

Data No.	Variabel Independen				Variabel Dependen
	Lingkar Dada	Panjang Badan	Tinggi Pinggul	Tinggi Pundak	Berat Badan
1	29,6	20,6	26,7	24,0	1,9
2	25,7	21,5	25,2	24,3	1,9
3	26,8	23,2	26,9	25,8	2,0
4	28,0	24,0	28,0	28,0	2,3
5	29,2	20,7	27,6	26,2	2,4
...

Tabel 5: Variabel independen dan dependen yang terpilih (setelah normalisasi)

Data No.	Variabel Independen				Variabel Dependen
	Lingkar Dada	Panjang Badan	Tinggi Pinggul	Tinggi Pundak	Berat Badan
1	0,067474	0,02686	0,030738	0,023904	0
2	0	0,045455	0	0,02988	0
3	0,019031	0,080579	0,034836	0,059761	0,00255102
4	0,039792	0,097107	0,057377	0,103586	0,01020408
5	0,060554	0,028926	0,04918	0,067729	0,0127551
...

Variabel-variabel independen yang telah lolos seleksi fitur beserta variabel dependen berat badan seluruhnya dinormalisasi agar nilainya berada dalam kisaran yang dapat diterima ANN sesuai fungsi aktivasi sigmoid dengan persamaan 2. Hasil dari normalisasi tersebut ditunjukkan pada tabel 5

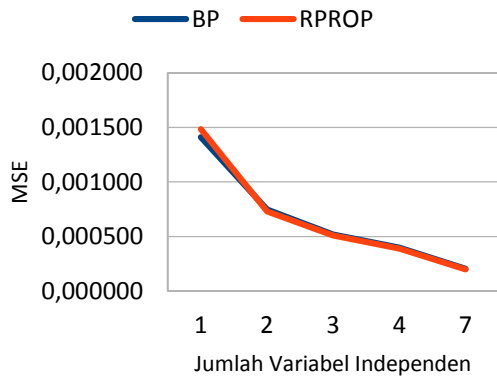
Perbandingan BP dan RPROP

Rekapitulasi nilai rata-rata MSE yang diperoleh untuk tiap percobaan yang dilakukan dapat dilihat pada tabel 6. Nilai rata-rata MSE terbesar diperoleh pada percobaan RPROP bobot awal acak dengan 1 variabel independen, yaitu 0,0014844857. Nilai rata-rata MSE terkecil 0,0001924905 diperoleh pada percobaan RPROP dengan 7 variabel independen.

Tabel 6: Nilai rata-rata MSE tiap percobaan

		BP	RPROP
Jumlah Variabel Independen	1	0,00141	0,001484
	2	0,000748	0,000731
	3	0,000518	0,000508
	4	0,000398	0,000388
	7	0,000204	0,000199

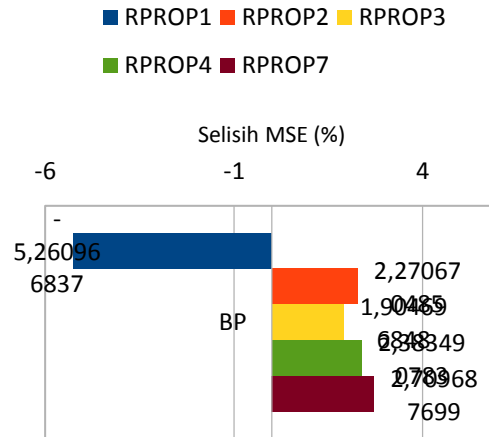
Gambar 3 menunjukkan rekapitulasi nilai rata-rata MSE tiap percobaan dalam bentuk grafik. Pada gambar tersebut terlihat bahwa penurunan nilai MSE seiring dengan penambahan variabel independen adalah tidak linier. Penurunan nilai MSE terbesar terjadi saat penambahan variabel independen dari satu buah menjadi dua buah.



Gambar 3: Grafik Rata-rata MSE

Grafik pada gambar 4 menunjukkan perbandingan nilai rata-rata MSE yang diperoleh metode *training* RPROP bobot awal acak relatif terhadap BP bobot awal acak. Dalam grafik tersebut, RPROP bobot awal acak dapat menghasilkan nilai rata-rata MSE yang lebih baik antara 1,90% - 2,71% lebih baik dibanding BP bobot awal acak untuk semua jumlah variabel yang diuji kecuali pada percobaan dengan 1 variabel independen. Pada percobaan dengan 1 variabel independen saja, nilai rata-rata MSE yang dihasilkan RPROP bobot awal acak justru lebih buruk 5,26%.

Gambar 3 menunjukkan grafik perbandingan nilai rata-rata MSE yang dihasilkan metode *training* RPROP bobot awal acak relatif terhadap RPROP dengan optimasi bobot awal menggunakan ABC. Pada grafik tersebut terlihat bahwa secara umum RPROP dengan optimasi bobot awal menggunakan ABC, dapat menurunkan MSE lebih lanjut dibanding RPROP bobot awal acak. Namun, besarnya penurunan MSE bervariasi. Penurunan MSE terkecil diperoleh pada percobaan dengan 1 variabel independen, sedangkan yang terbesar diperoleh pada percobaan tanpa seleksi fitur. Hal lain yang dapat dilihat dari grafik tersebut adalah penurunan nilai MSE tidak sejalan dengan penambahan variabel independen yang digunakan. Penurunan MSE pada percobaan dengan 3 variabel independen lebih besar daripada dengan 2 variabel independen. Namun, penurunan MSE pada percobaan dengan 4 variabel independen tidak lebih besar dari percobaan dengan 3 variabel independen.



Gambar 4: Grafik selisih MSE RPROP terhadap MSE BP

Pada gambar 4 merupakan grafik perbandingan nilai rata-rata MSE metode *training* RPROP dengan optimasi bobot awal menggunakan ABC relatif terhadap BP bobot awal acak. Pada grafik tersebut terlihat bahwa untuk semua jumlah independen variabel yang diuji RPROP dengan optimasi bobot awal menggunakan ABC dapat menghasilkan MSE yang lebih baik antara 4,41% - 5,66% kecuali pada percobaan dengan 1 variabel independen. Pada percobaan dengan 1 variabel independen, optimasi bobot awal menggunakan ABC tampaknya tidak sanggup untuk membuat metode *training* RPROP menjadi lebih baik MSE-nya dibanding BP bobot awal acak.

KESIMPULAN

Dalam penelitian ini, terlihat bahwa metode *training* RPROP bobot awal acak dapat menghasilkan model dengan nilai MSE yang lebih baik antara 1,90% - 2,71% dibanding metode *training* BP bobot awal acak. Namun, pada percobaan dengan 1 variabel independen, nilai MSE yang dihasilkan metode *training* RPROP bobot awal acak justru lebih buruk 5,26% dibanding metode *training* BP bobot awal acak. Tampaknya, dalam penelitian ini, RPROP mengalami kesulitan untuk menyaingi metode *training* BP jika variabel independen yang digunakan terlalu sedikit.

Pada percobaan dengan 1 variabel independen, nilai MSE-nya masih lebih buruk 5,11%. Nilai MSE ini masih lebih baik daripada nilai MSE yang dihasilkan metode *training* RPROP bobot awal acak, tetapi tidak cukup untuk menyaingi metode *training* BP bobot awal acak.

DAFTAR PUSTAKA

- I. Budisatria, H. Mulyadi, K. Santosa, B. Suhartanto, D. Widayati and K. Adiwimarta, *Plasma Nutfah Kambing di Indonesia*. Yogyakarta: Fakultas Peternakan Universitas Gajah Mada, 2009.
- I. Utama and I. Budiarsana, *Panduan Lengkap Kambing dan Domba*. Jakarta: Penebar Swadaya, 2009.
- G. Wang, J. Wu, J. Wu and X. Wang, "A Comparison between the Linear Neural Network Method and the Multiple Linear Regression Method in the Modeling of Continuous Data", *JCP*, vol. 6, no. 10, 2011.
- H. Shi, K. Lee, H. Lee, W. Ho, D. Sun, J. Wang and C. Chiu, "Comparison of Artificial Neural Network and Logistic Regression Models for Predicting In-Hospital Mortality after Primary Liver Cancer Surgery", *PLoS ONE*, vol. 7, no. 4, p. e35781, 2012.
- M. Behzadi and A. Aslamineja, "A Comparison of Neural Network and Nonlinear Regression Predictions of Sheep Growth", *J. of Animal and Veterinary Advances*, vol. 9, no. 16, pp. 2128-2131, 2010.
- D. Cavero, K. Tölle, C. Henze, C. Buxadé and J. Krieter, "Mastitis detection in dairy cows by application of neural networks", *Livestock Science*, vol. 114, no. 2-3, pp. 280-286, 2008.
- S. Shahinfar, H. Mehrabani-Yeganeh, C. Lucas, A. Kalhor, M. Kazemian and K. Weigel, "Prediction of Breeding Values for Dairy Cattle Using Artificial Neural Networks and Neuro-Fuzzy Systems", *Computational and Mathematical Methods in Medicine*, vol. 2012, pp. 1-9, 2012.
- M. Lopez-Benavides, S. Samarasinghe and J. Hickford, "The use of artificial neural networks to diagnose mastitis in dairy cattle", *Proceedings of the International Joint Conference on Neural Networks*, 2003..
- Y. Wang, W. Yang, P. Winter and L. Walker, "Walk-through weighing of pigs using machine vision and an artificial neural network", *Biosystems Engineering*, vol. 100, no. 1, pp. 117-125, 2008.
- A. Saefudin, K. Anwar Notodipuro, A. Alamudi and K. Sadik, *Statistika Dasar*. Jakarta: Grasindo, 2009.
- Phillips, J. Phillips and B. Aaron, *Survey basics*. Alexandria, Va.: ASTD Press, 2013.
- Shalabi, Z. Shaaban and B. Kasasbeh, "Data Mining: A Preprocessing Engine", *J. of Computer Science*, vol. 2, no. 9, pp. 735-739, 2006.
- Francis, "Neural networks demystified", in *Casualty Actuarial Society Forum*, 2001, pp. 253-320.
- M. Zaefizadeh, A. Jalili, M. Khayatnezhad, R. Gholamin and T. Mokhtari, "Comparison of multiple linear regressions (MLR) and artificial neural network (ANN) in predicting the yield using its components in the hullless barley", *Advances in Environmental Biology*, pp. 109-114, 2011.
- A. Comrie, "Comparing Neural Networks and Regression Models for Ozone Forecasting", *Journal of the Air & Waste Management Association*, vol. 47, no. 6, pp. 653-663, 1997.
- T. Sutojo, E. Mulyanto and V. Suhartono, *Kecerdasan Buatan*. Yogyakarta: Penerbit ANDI, 2011.
- Hecht-Nielsen, "Theory of the backpropagation neural network", *International Joint Conference on Neural Networks*, 1989.
- Y. Chauvin and D. Rumelhart, *Backpropagation*. Hillsdale, N.J.: Lawrence Erlbaum Associates, 1994.
- C. Igel and M. Hüsken, "Empirical evaluation of the improved Rprop learning algorithms", *Neurocomputing*, vol. 50, pp. 105-123, 2003.
- M. Reidmiller and H. Braun, "RPROP-A fast adaptive learning algorithm", in *Proceedings of the International Symposium on Computer and Information Science VII*, 1992.
- D. Karaboga and B. Akay, "A comparative study of Artificial Bee Colony algorithm", *Applied Mathematics and Computation*, vol. 214, no. 1, pp. 108-132, 2009.
- E. Salawu, M. Abdulraheem, A. Shoyombo, A. Adepeju, S. Davies, O. Akinsola and B. Nwagu, "Using Artificial Neural Network to Predict Body Weights of Rabbits", *Open Journal of Animal Sciences*, vol. 04, no. 04, pp. 182-186, 2014.