

PEMODELAN KONDISI UDARA ATAS DENGAN BACK-PROPAGATION NEURAL NETWORK DAN PEMANFAATANNYA UNTUK PENENTUAN HARI SEMAI

Mahally Kudsy¹

Intisari

Jaringan syaraf buatan dengan penyebaran ke belakang dipakai untuk memodelkan hubungan parameter udara atas yang dihasilkan dengan rawinsonde dengan kelayakan hari semai. Data rawinsonde dari periode 1995-1999 dari Semarang dan Bandung dipakai untuk melatih jaringan. Jaringan terdiri dari 10 buah simpul pada layer input, 40 simpul pada layer tersembunyi dan 2 buah simpul pada layer output. Jumlah simpul yang optimal pada layer tersembunyi untuk memodelkan 10 parameter udara atas adalah 40 buah. Banyaknya iterasi yang optimal untuk mencapai konvergensi dengan kesalahan rata-rata kuadrat 0.05 adalah 700 kali. Jaringan yang dihasilkan dapat menghasilkan prakiraan kelayakan hari semai atau tidak dengan tingkat ketelitian yang lebih besar dari 75%.

Abstract

A back-propagation artificial neural network was used to model the relationship between upper-air parameters obtained by rawinsonde and the seeding day favorability. A series of data obtained from rawinsonde launched at Semarang and Bandung from 1995-1999 period was used as input or training data. The network comprised of 10, 40 and 2 simpuls located at the input, hidden and output layers respectively. The optimum number of hidden units of this network was 40. The training iteration required to reach convergence with RMS error of 0.05 was 700. The network resulted can predict the seeding favorability greater than 75% accuracy.

Kata kunci: jaringan syaraf artifisial, rawin sonde, penyemaian awan

1. PENDAHULUAN

Salah satu masalah penting dalam setiap kegiatan modifikasi cuaca adalah penentuan apakah pada suatu hari tertentu layak untuk diadakan penyemaian awan atau tidak. Salah satu wahana yang dipakai untuk penentuan kelayakan tersebut adalah dengan analisis udara atas dengan radio sonde. Dari pengamatan radio sonde diperoleh parameter-parameter seperti *Ki*, *precipitable water* (PW), *total totals index*, dan lain-lain. Parameter-parameter tersebut diciptakan di negara-negara subtropis, namun pada prakteknya banyak dipakai di Indonesia termasuk di UPT Hujan Buatan untuk memprakirakan kondisi suatu hari operasi.

Metoda diatas mempunyai kelemahan, karena kondisi alam di Indonesia berbeda dengan

tempat dimana indeks-indeks itu dihasilkan. Karena itu penulis mempunyai pendapat bahwa sebaiknya kita mempunyai kriteria-kriteria sendiri untuk membuat interpretasi hasil pengamatan udara atas dengan rawin sonde.

Pada tulisan ini penulis memakai metoda *back propagation neural networks* untuk merekonstruksi kondisi udara atas berdasarkan data yang telah dimiliki oleh UPT Hujan Buatan selama penulis mengikuti kegiatan modifikasi cuaca sejak tahun 1994. Metoda ini telah dicoba diterapkan untuk menganalisis aliran yang masuk ke Danau Towuti (Kudsy dan Husni, 2000), dimana hasilnya sesuai dengan penelitian hidrologi yang dimengerti sampai saat ini. Aplikasi lain dari neural network juga telah diterapkan misalnya dalam segmentasi atau pengenalan awan (Yhann dan Simpson, 1995).

¹ UPT Hujan Buatan, BPP Teknologi Lt. 19 Gd. 1 Jl. M.H. Thamrin No. 8, Jakarta 10340

2. METODA DAN DATA

Jaringan syaraf buatan yang dipakai untuk membuat korelasi antara parameter-parameter udara atas terdiri dari 1 layer input (10 simpul), 1 layer tersembunyi (40 simpul) dan 1 layer output (2 simpul). Parameter-parameter yang dipakai pada layer input adalah K_i , PW , $T850$, $T700$, RH_s , $RH850$, $RH700$, $RH550$, $Ws700$, $Wd700$. Makna dari notasi-notasi ini dapat dilihat di bagian akhir dari tulisan ini. Data yang dipakai adalah dari kumpulan data radio sonde dari Semarang dan Bandung dari periode 1995-1999. Jumlah set data yang dipakai dari kedua lokasi adalah 115 buah.

Tabel 1 Kriteria parameter udara atas yang dipakai sebagai data training

Parameter	Maksima	Mimima
Ki	20	40
Pw	1	2.5
WD	1 (Baratan)	0 (Timuran)
WS	0 knot	15 knot
Parameter lain	Seperti adanya	

Data-data yang dipakai dinormalisasi sehingga terletak pada maksima (1) dan minimanya (0) dengan cara linier. Layer output terdiri dari 2 simpul yang terdiri dari 0.9 dan 0.1 yang menggambarkan kondisi pada hari tersebut yaitu favorable dan unfavorable. Kondisi dianggap favorable bila diperoleh hujan rata-rata wilayah yang aktual ≥ 5 mm. Pemilihan angka 0.9 dan 0.1 lebih baik dari angka 1 dan 0. Dengan kedua angka tersebut diharapkan tidak ada nilai yang melebihi 1 (favorable) atau lebih kecil dari 0 (unfavorable). Dengan metoda di atas maka network hanya akan menangani nilai-nilai yang terletak di antara 0 dan 1.

Bobot dari network pada setiap simpul (w_{ij}) dihitung dengan algoritma umum sebagai berikut (Beale dan Jackson, 1991):

1. Inisiasi bobot dan threshold.
2. Hitung output pada setiap layer dengan memakai output dari layer sebelumnya sebagai input

$$y_{pj} = f \left[\sum_{i=0}^{n-1} w_{ij} x_i \right]$$

3. Output dari prosedur (2) dipakai sebagai input untuk layer berikutnya, sampai pada layer terakhir diperoleh output
4. Perbaiki bobot dimulai dari layer output terakhir dan bergerak ke belakang dengan

$$w_{ij}(t+1) = w_{ij}(t) + \eta d_{pj} o_{pj}$$

Untuk simpul output

$$d_{pj} = k o_{pj} (1 - o_{pj}) (t_{pj} - o_{pj})$$

Untuk simpul tersembunyi

$$d_{pj} = k o_{pj} (1 - o_{pj}) \sum_k d_{pk} w_{jk}$$

5. Dengan bobot dan threshold yang baru, ulangi lagi dari prosedur 2 sampai kesalahan (RMS) pada output lebih kecil dari kesalahan yang telah ditetapkan. (0.05)

Pada analisis ini bobot atau weight serta threshold diinisiasi dengan bilangan yang dipilih secara acak dan terletak pada range -0.35 sampai 0.35. Gain dipilih 0.03

3. HASIL DAN PEMBAHASAN

3.1. Banyaknya hidden unit dan hidden layer dan iterasi

Banyaknya hidden layer merupakan gambaran dari parameter-parameter yang tidak secara eksplisit diterangkan sebagaimana pada input layer. Secara implisit hal ini juga menunjukkan tingkat kerumitan dari peristiwa-peristiwa fisis yang ada. Sebagai contoh dalam masalah analisis rawin sonde adalah ketebalan lapisan boundary layer yang berbeda dari satu tempat dengan lainnya. Untuk daerah Bandung, ketebalan mixing layer sering diasumsikan 50 mbar sedang untuk daerah Semarang pernah pula dipakai 100 mbar. Perbedaan mixing layer ini seharusnya dapat direpresentasikan sebagai *data class* yang berbeda sehingga dengan demikian akan menambahkan sebuah lagi hidden layer. Dengan hidden simpul sebanyak 40 buah, maka untuk mencapai konvergensi sehingga kesalahan lebih kecil dari yang dibolehkan maka network harus dilatih sebanyak 700 kali (iterasi). Jelas, banyaknya iterasi yang diperlukan ternyata bergantung pula banyaknya simpul tersembunyi pada hidden layer. Semakin banyak simpul yang dipakai atau semakin besar jaringan, pada umumnya semakin banyak pula iterasi yang diperlukan untuk mencapai konvergensi (Hertz *et al.*, 1991). Dengan 45 buah hidden unit yang terletak pada sebuah hidden layer diperlukan 1200 iterasi untuk mencapai konvergensi dengan residu kesalahan 0.05. Penambahan iterasi di dalam neural network tidak selalu menguntungkan, bahkan ada kalanya merugikan dengan apa yang disebut bahwa jaringan tersebut **overtrained**. Jaringan syaraf pada tulisan ini hanya dipilih satu saja dengan maksud untuk mendapatkan gambaran tentang ketelitian jaringan syaraf ini. Banyaknya iterasi yang diperlukan dapat dilihat pada Tabel 2.

Dengan hidden unit sebanyak 35 buah jaringan tidak dapat bekerja. Dari Tabel 2 tampak bahwa dengan 38 buah hidden unit maka banyaknya iterasi yang diperlukan untuk mencapai konvergensi dengan error 5% adalah 2000. Dengan 40 buah hidden unit jaringan hanya memerlukan 700 iterasi untuk mencapai konvergensi, maka jelas adanya kecenderungan overtrained dengan 38 buah hidden unit. Karena itu maka disini dapat dianggap bahwa jaringan ini optimal dengan 40 buah hidden unit pada sebuah hidden layer.

Banyaknya bobot dari jaringan ini adalah $10 \times 40 \times 2 = 800$ buah. Karena jumlahnya yang sangat banyak, maka untuk praktisnya tidak dimuat dalam tulisan ini.

Tabel 2. Banyaknya iterasi sebagai fungsi hidden unit. Pengurangan jumlah hidden unit tidak selalu menguntungkan dari segi pemakaian CPU.

Jumlah hidden unit	Iterasi (RMS = 0.05)
35	Tidak diketahui
38	2000
39	700
40	700
45	1200

3.2. Pemakaian jaringan untuk prakiraan hari semai.

Penentuan hari semai atau tidak di dalam praktek sering menyimpang dari kriteria-kriteria yang telah ditetapkan pada awal kegiatan karena adanya perkembangan yang terjadi secara aktual di lapangan. Walaupun begitu, untuk kepentingan seperti penelitian dimana kriteria-kriteria dipatuhi secara ketat, maka pemanfaatan jaringan syaraf buatan dapat dipakai untuk menentukan apakah suatu hari favorable atau tidak. Walaupun pada akhirnya penentuan favorable atau tidak bergantung pada prakiraan dari wahana lainnya (pibal dan satelit), paling tidak aplikasi ini dapat dipakai dari wahana udara atas.

Jaringan yang terlatih ini dapat dipakai untuk menganalisis kondisi (data). Tabel 3 memuat beberapa contoh kondisi udara atas dan hasil prakiraan dengan jaringan yang terlatih.

Dari Tabel 3 tampak bahwa besarnya nilai Ki saja tidak dapat menunjukkan bahwa suatu hari akan favorable atau tidak. Demikian pula dengan kelembaban. Pada kolom (2) Tabel 3, walaupun kelembaban dari surface sampai dengan 500 mbar cukup tinggi (semuanya di atas), namun karena adanya kecepatan angin yang tidak menguntungkan pada 700 mbar, maka jaringan menghasilkan prakiraan hari tersebut sebagai unfavorable. Pada kolom (3), Ki yang diperoleh pada pagi hari adalah 23 dan nampak berkabut

yang ditunjukkan dengan RH lebih besar 90% pada semua lapisan dari permukaan sampai dengan 500 mbar, namun network menghasilkan prakiraan favorable untuk hari tersebut.

Tabel 3. Prediksi hari semai berdasarkan data udara atas dari rawin sonde dengan jaringan yang terlatih memakai data representatif dari Bandung dan Semarang

No.	(1)	(2)	(3)	(4)
Ki	35	27	22	35
PW	1.5	1.2	2.2	23
T850	15.6	14.5	15.2	14.5
T700	7.2	7.5	6.8	7.0
RHs	72	83	90	78
RH850	65	80	90	85
RH700	70	80	65	42
RH550	70	75	45	42
WS700	1	0	1	0
WD700	1	1	1	1
OUT1	0.91	0.99	0.86	0.43
OUT	0.09	0.01	0.14	0.53
DECLR	Fav	Unf	Fav	Unf.

1, 2, 3 Data rawinsonde Semarang

4 Data rawinsonde Bandung

Ketelitian prakiraan dengan network ini tentu saja harus diuji terus menerus serta divalidasi dengan data baru. Hasil yang diperoleh dapat ditambahkan sebagai data training baru untuk meningkatkan ketelitian prakiraan. Perlunya training lebih lanjut adalah hasil yang diperoleh oleh kolom 4 yang dihasilkan dari data Bandung, dimana nilai luaran 1 (out1) dan luaran 2 (out2) tidak berbeda jauh. Ambiguitas ini boleh jadi dihasilkan karena kurangnya hidden layer yang dipakai di dalam menyusun jaringan.

Dari pengamatan hasil prakiraan dengan bagian data yang tidak dipakai untuk melatih, ketelitian prakiraan adalah lebih besar dari 75%. Angka ini dengan membandingkan banyaknya prediksi yang favorable menurut neural network dan jumlah hari yang secara aktual favorable.

4. KESIMPULAN DAN SARAN

Dari studi ini dapat disimpulkan bahwa jaringan syaraf buatan atau artificial neural network dapat dipakai untuk menganalisis, memodelkan dan merekonstruksi peristiwa-peristiwa fisis yang melibatkan banyak parameter. Dalam studi ini telah dihasilkan jaringan syaraf buatan (artificial neural network) dengan metoda *back-propagation*. Hasil studi menunjukkan suatu hal yang cukup menggembirakan, yaitu bahwa hasil prakiraan yang dihasilkan adalah 75 % akurat. Ketelitian ini dapat ditingkatkan apabila pada jaringan tersebut ditambahkan satu hidden layer baru yang menunjukkan adanya perbedaan

kelas data yang diakibatkan oleh perbedaan topografi dari kedua daerah. Perbedaan topografi mengakibatkan perbedaan mixing layer antara kedua tempat (Bandung dan Semarang).

Metoda neural network dapat memecahkan persoalan dengan cepat. Kegunaan metoda ini untuk menentukan hari yang favorable untuk penyemaian akan lebih terasa apabila analisis awan dan kondisi lokal diintegrasikan ke dalam satu jaringan.

Notasi

y_{pj}	output dari simpul j dari set p
w_i	bobot pada simpul i
x_i	input pada simpul i
o_{pj}	output pada layer terakhir pada set p
h	gain
d_{pj}	error pada simpul j pada pattern p
k	banyaknya simpul yang ada di atas simpul j
K_i	severe weather index
PW	precipitable water
$T850$	suhu udara pada paras 850 mbar
$T700$	suhu udara pada paras 700 mbar

RHs	kelembaban pada permukaan
$RH850$	kelembaban pada paras 850 mbar
$RH700$	kelembaban pada paras 700 mbar
$RH550$	kelembaban pada paras 550 mbar
$WS700$	kecepatan angin pada paras 700 mbar
$WD700$	arah angin pada paras 700 mbar

5. DAFTAR PUSTAKA

- Beale, R dan Jackson, T., 1991, *Neural Computing*, New York, USA, IOP Publishing
- Kudsy, M dan Husni, M., 2000, "Respons Aliran Masuk ke Danau Towuti oleh Curah Hujan di Wawondula dan Sekitarnya Dianalisa Dengan Neural Network", *J. Sains & Iptek Modif. Cuaca*, Vol 1, No. 1.
- Hertz, J., Krogh, A. dan Palmer, R., 1991, *Introduction to the Theory of Neural Computation*, Redwood City, CA: Addison Wesley.
- Yhann, S.R dan Simpson, J., 1995 "Application of Neural Networks to AVHRR Cloud Segmentation", *.IEEE Trans. On Geoscience and Remote Sensing*, 33(3)

DATA PENULIS



Mahally Kudsy, lahir di Sumenep (1956), menamatkan pendidikan formal S1 Teknik Kimia UGM (1980), S2 Bidang Combustion dan Energy, Universitas Leeds, Inggris (1986), dan S3 bidang Teknik Kimia, Universitas Kyoto, Jepang (1993). Bekerja di BPPT sejak 1981, di UPTHB-BPPT sejak 1993. Mengikuti beberapa training mengenai komputasi, komunikasi data dan modeling baik di luar negeri maupun dalam negeri. Training modeling RSM di IRI, UCSD, San Diego (1998). Sejak bekerja di UPTHB-BPPT penulis banyak menekuni tentang komunikasi data dan pengolahan data meteorologi.