

Perbandingan Pemodelan Hujan-Limpasan antara *Artificial Neural Network* (ANN) dan NRECA

Wanny K. Adidarma¹⁾
Iwan K. Hadihardaja²⁾
Sri Legowo³⁾

Abstrak

Analisa ketersediaan air memerlukan data debit yang relatif cukup panjang dan kontinyu. Jika data debit yang tersedia tidak cukup panjang dan kontinyu maka diperlukan model hubungan hujan-limpasan.

Salah satu model yang tersedia, dimana parameter-parameter yang membentuk suatu persamaan yang memiliki arti fisik yang mengilustrasikan air permukaan dan air tanah pada suatu sungai dikenal dengan NRECA (Non Recorded Catchment Area). Pemodelan yang lain, diantaranya adalah Artificial Neural Network (ANN) yang merupakan elemen-elemen yang saling berhubungan dengan simpul-simpul dan dianalogikan sebagai neuron. Neural network memiliki lapisan input dan output yang saling berhubungan dan akan memiliki pola arsitektur berbeda-beda tergantung dari kendala dalam suatu permasalahan.

Data hujan bulanan merupakan input sedangkan data debit bulanan merupakan variabel output. Perbedaan hasil simulasi debit bulanan yang dihasilkan dengan model ANN atau Nreca dan hasil debit pengamatan akan ditentukan berdasarkan error mutlak rata-rata yang disebut KAR (Kesalahan Absolut Rata-rata).

Studi kasus yang digunakan adalah data hujan bulanan dan debit di Cikapundung-Gandok selama kurun waktu 30 tahun. Untuk NRECA, semakin besar error yang diperoleh KAR, semakin besar deviasi debit yang terjadi. Dalam studi ini dapat disimpulkan bahwa secara umum NRECA memberikan hasil yang lebih baik kecuali untuk kondisi low flow.

Kata-kata kunci: artificial neural network, teknik non linier, model balck box hujan-limpasan.

Abstract

The analysis of water availability needs continuous and long discharge data. If the data is not long and continuous thus the rainfall-runoff model is needed.

One of the available models, where parameters forming equation which have physical meaning illustrate ground water and surface runoff in the river, is NRECA (Non Recorded Catchments Area). Another model, an artificial neural network (ANN) is a computing system made up of a highly interconnected set of simple information processing elements, analogous to a neuron, called units. A neural network has an input layer, a hidden layer and an output layer. Each layer is made up of several nodes, and layers are interconnected by sets of correlation weights. The pattern of connectivity and the number of processing units in each layer may vary within some constraints.

The input used is monthly rainfall whereas the output is monthly discharge. The difference between simulated discharge produced by ANN or NRECA and observed discharge is determined by mean absolute error, namely KAR (Kesalahan Absolut Rata-rata).

For case study, 30 year monthly rainfall and discharge at Cikapundung-Gandok are used. For NRECA, the more error on KAR, the more deviation of discharge will be, particularly which is under average for dependable discharge as well as mean annual minimum discharge. It is concluded that in general NRECA is better but especially for low flow ANN model is leading.

Keywords: artificial neural network, non linier technique, rainfall-runoff black box model.

1. Peneliti Bidang Hidrologi Pusair dan Mahasiswa Program Pasca Sarjana-UNPAR
2. Staf Pengajar Departemen Teknik Sipil FTSP-ITB

Catatan : Usulan makalah dikirimkan pada 30 Juli 2004 dan dinilai oleh peer reviewer pada tanggal 11 Agustus 2004 – 18 Oktober 2004. Revisi penulisan dilakukan antara tanggal 20 Oktober 2004 hingga 1 Nopember 2004.

1. Pendahuluan

Model hubungan hujan-limpasan masih tetap dibutuhkan sampai saat ini, baik untuk pengisian data maupun untuk memperpanjang data. Yang terakhir lebih banyak digunakan karena data hujan umumnya lebih panjang daripada data debit. Model hubungan hujan limpasan yang berkesinambungan (*continuous model*) biasanya menggunakan interval waktu bulanan serta model hubungan hujan limpasan yang bersifat per kejadian (*event-model*) menggunakan interval waktu lebih pendek seperti jam-jaman atau lebih kecil dari satu jam untuk DPS kecil.

Model-model tersebut dibentuk oleh satu set persamaan matematis yang mencerminkan perilaku aliran di DPS, melalui sistim lumped atau distributed, sehingga parameter-parameter yang terkandung dalam persamaan tersebut mempunyai arti fisik. Tahap kalibrasi parameter merupakan tahap yang terpenting agar menghasilkan perpanjangan data debit yang handal.

Alternatif lain, dalam memodelkan hujan-limpasan yang berkesinambungan adalah dengan menggunakan *Artificial Neural Network (ANN)*. Model ini menggunakan satu set persamaan matematis linier dan non-linier yang tidak memperhitungkan sama sekali proses fisiknya, yang penting output yang dihasilkan mendekati yang sebenarnya.

Kedua macam pendekatan tersebut dapat menghasilkan output yang secara garis besar mirip tetapi dengan tingkat keandalan yang berbeda. Dalam beberapa hal model yang mempunyai arti fisik mempunyai keuntungan seperti parameter-parameternya dapat digunakan dalam analisis wilayah. Selanjutnya, parameter yang sudah diperkirakan dapat digunakan untuk generate data debit di lokasi yang tidak mempunyai data pengamatan. Dengan ANN hal tersebut sulit dilakukan.

Bagaimanapun juga, makalah ini mencoba untuk menerapkan ANN pada hubungan hujan-limpasan dengan menggunakan back-propagation yang dikerjakan oleh Solver Excel. Struktur model digambarkan oleh tatanan deret data hujan dan debit dalam wahana *input-hidden-output layers* dengan jaringan tertentu. Sekali struktur dari input-hidden-output layers sudah ditentukan, dapat digunakan untuk input-output dari DPS lain.

2. Model NRECA

Ada banyak model sinambung yang dipakai saat ini, salah satu model yang sering digunakan karena kesederhanaannya adalah Model NRECA dikembangkan

oleh Crawford. Model ini dikhususkan untuk interval waktu bulanan, sedangkan model-model lain dapat menggunakan interval harian seperti SSARR, Sacramento. Model NRECA seringkali dipakai karena input data hujan bulanan lebih mudah didapatkan dibandingkan hujan harian, disamping itu jumlah parameter yang cukup besar pengaruhnya hanya dua buah, selebihnya dapat dikategorikan pengaruh kecil jumlahnya berkisar tiga buah.

Dua parameter utama yaitu PSUB dan GWF. Yang pertama, PSUB, menggambarkan bagian kelebihan air hujan yang masuk ke dalam tampungan air tanah serta yang kedua, GWF, mencerminkan bagian dari tampungan air tanah yang mengkontribusi aliran air di sungai. Selain dari tampungan air tanah, aliran air di sungai berasal sebagian dari kelebihan kelengasan air tanah (*Excess Soil Moisture*) sebesar (1-PSUB). Selain parameter utama kondisi awal ketersediaan air di zona kelengasan tanah juga perlu dikalibrasi meskipun pengaruhnya tidak terlalu besar. Di samping itu, faktor tanaman (*crop factor*), CF, kerap dikalibrasi dalam nilai batas yang diijinkan untuk menyesuaikan dengan kondisi tanaman setempat.

Dengan demikian pengkalibrasiannya lebih mudah pula dilakukan. Input data lain yang digunakan adalah evapotranspirasi dan data debit hasil pengamatan. Data evapotranspirasi sangat terbatas jumlahnya sehingga yang digunakan hanya satu tahun saja, hal ini merupakan masalah tersendiri yang biasanya diatasi dengan memberikan crop factor sebagai faktor pengali. Oleh karena itu, data evapotranspirasi tidak digunakan sebagai deret data yang lain seperti hujan dan debit pada model ANN.

Ukuran kedekatan antara debit hasil perhitungan model dan debit pengamatan dituangkan dalam bentuk fungsi objektif atau fungsi kesalahan yang merupakan persamaan dari selisih perhitungan dan pengamatan. Bentuk dari fungsi ini dapat bermacam-macam, pemilihan fungsi berdasarkan Adidarma et al. (1999) yaitu :

KesalahanAbsolutRata – rata(KAR)

$$= 1/n \sum \frac{Abs(Q_{comp} - Q_{obs})}{Q_{obs}} \tag{1}$$

di mana Q_{comp} adalah debit hasil perhitungan dan Q_{obs} adalah debit pengamatan dengan ukuran sampel n. Nilai KAR lebih memperhatikan debit kecil daripada debit besar sehingga sangat bermanfaat bagi pengembangan sumber daya air.

3. Model Artificial Neural Network (ANN)

Model ANN merupakan tiruan cara kerja syaraf, di mana komponen-komponennya terdiri dari input sinyal yang digambarkan oleh variabel X. Setiap input dirubah oleh faktor bobot yang menggambarkan simpul syaraf biologis, faktor bobot tersebut saling berinteraksi satu sama lain membentuk sebuah konfigurasi yang menghasilkan output sinyal berupa variabel Y.

Tsoukalas et al. (1996), perhitungan elemen dalam proses tersebut mencakup dua bagian yaitu bagian yang pertama adalah jumlah komponen input yang sudah dikalikan dengan faktor bobotnya dan menghasilkan besaran I. Dan, bagian kedua merupakan filter non-linier yang sering disebut activation function melalui titik ini sinyal I dapat mengalir.

Dimana

$$I_j = \sum w_{ij}x_j \quad (2)$$

$$y_j = \Phi(I_j) \quad (3)$$

Persamaan 3 yang disebut activation function (lihat **Gambar 1**) dapat berupa :

fungsi logistik :

$$\Phi(I) = \frac{1}{(1 + e^{-\alpha I})} \quad (4)$$

fungsi tangen hiperbolis

$$\Phi(I) = \tanh(\alpha I) = \frac{e^{\alpha I} - e^{-\alpha I}}{e^{\alpha I} + e^{-\alpha I}} \quad (5)$$

Kegunaan dari *activation functions* adalah memeras fungsi output supaya berada dalam batas-batas yang diinginkan yaitu berada diantara dua garis asimtot nol


dan satu atau minus satu dan satu. Batas tersebut sangat bermanfaat dalam menjaga agar supaya output dari proses elemen-elemen senantiasa berada dalam atas dinamis yang handal.

Proses elemen-elemen disusun dalam urutan lapisan yang dilengkapi dengan penghubung antar lapisan. Rangkaian dalam **Gambar 2** menunjukkan lapisan data input pada jaringan, sebelum mencapai lapisan output ada lapisan antara yang disebut hidden layer.


Dalam contoh di atas lapisan antara hidden layer hanya satu pada struktur lain dapat berjumlah lebih dari satu dengan jumlah node k buah, input k buah dan output m buah. Setiap garis penghubung mengandung faktor bobot yang digunakan untuk mengalih input yang masuk simpul selanjutnya dijumlahkan dan dirubah fungsi oleh activation function menjadi output dari simpul yang bersangkutan yang siap untuk dihitung melalui **persamaan 2** atau **3**. Proses ini berlangsung dari satu simpul ke simpul lain pada lapisan yang berbeda sampai akhir mencapai terminal akhir yaitu output y.

Proses perhitungan yang mengalir dari lapisan input ke output disebut *feedforward*. Jika proses perhitungan ini dilakukan hasil akhir yang didapat belum tentu sama dengan output yang diharapkan, yang memegang peranan penting dalam menghasilkan output adalah besarnya faktor bobot w_{ij} bentuk activation function dan akhirnya struktur model. Oleh karena itu, satu set faktor bobot harus dioptimisasi sehingga menghasilkan output di lapisan terakhir yang mendekati data pengamatan. Perubahan nilai w_{ij} tergantung besarnya nilai KAR, dengan demikian sistim perhitungan tidak lagi satu arah (input ke output) melainkan dua arah dan disebut *back-propagation*.

Back-propagation merupakan bagian dari training-process atau proses pembelajaran untuk mendapatkan nilai-nilai w_{ij} yang optimal. Sekali nilai tersebut



Gambar 1. Gambaran skematik sebuah neuron



Gambar 2. Struktur model tiga lapis

didapatkan maka set yang sama dapat digunakan dengan menggunakan feed-forward untuk menghitung outputnya, sistem pendekatan ini disebut recall, dalam model hidrologi setara dengan tahap verifikasi atau prediksi, sedangkan back-propagation sama dengan tahap kalibrasi.

Ada beberapa metodologi yang dapat digunakan untuk menjalankan back-propagation, salah satu cara yang dapat digunakan adalah dengan Solver Microsoft Excel. Kelemahan menggunakan perangkat lunak tersebut adalah jumlah wij yang dicari tidak boleh lebih dari 100 buah, sehingga mengurangi jumlah hidden layer. Kelebihan yang diperoleh adalah kemudahan dalam menerapkan ANN karena tidak membutuhkan perangkat lunak khusus yang sulit didapat.

Menurut French et al. (1992) dalam makalah Raman et al. (1995) ada beberapa keuntungan lain dalam menggunakan ANN antara lain :

1. penerapan dari ANN tidak memerlukan pengetahuan yang mendalam tentang proses fisik melatar belakangi hubungan antara variabel X dan Y,
2. tidak memerlukan pengetahuan akan hubungan yang kompleks antar berbagai aspek dalam proses tersebut yang membutuhkan penyelidikan.

4. Proses Pembelajaran JST dengan Teknik Optimasi

Proses pembelajaran (*training*) JST yang diterapkan dalam penelitian ini adalah dengan menggunakan *Program Non Linier* iteratif yang dikembangkan dari *Reduced Gradient Methods*. Metode ini (*Reduced Gradient Methods*) mencoba mempertahankan kelayakan pada setiap iterasi. Pendekatan tersebut memiliki banyak keuntungan. Jika setiap estimasi adalah layak, algoritma dapat dihentikan sebelum konvergen dan solusi pendekatannya tetap dapat digunakan. Proses konvergensi dapat dilihat pada setiap iterasi yang diukur langsung dengan menggunakan nilai dari fungsi objektifnya (Nash, 1996).

Teknik optimasi yang diterapkan dalam proses pembelajaran JST dalam penelitian ini memiliki fungsi tujuan (*objective function*) dan fungsi kendala (*constraint function*). Prinsip formulasi teknik optimasi untuk proses pembelajaran JST memiliki prinsip yang sama seperti yang diberikan dalam Hadihardaja (2003) untuk memprediksi sedimen berdasarkan *stremflow*. Demikian juga halnya seperti yang diformulasikan oleh Darman dan Hadihardaja (2003) untuk memprediksi debit sintetik (*time series*) yang formulasi teknik optimasinya dapat dianalogikan sama dengan teknik optimasi yang digunakan dalam permasalahan pada studi ini.

Fungsi tujuan (*objective function*) seperti yang telah dikembangkan dalam Hadihardaja (2003) dan Darman dan Hadihardaja (2003) tersebut, pada hakekatnya memiliki fungsi tujuan dengan meminimalkan kesalahan (*minimize error*) atau E sebagai berikut:

$$e = \frac{1}{2} \sum_{k=1}^m (T_k - O_k)^2 \quad (6)$$

Sehingga rata-rata kesalahan sistem (*Mean Square Error*) untuk semua pola input adalah

$$E = \frac{1}{2N} \sum_{p=1}^N \sum_{k=1}^m (T_{p,k} - O_{p,k})^2 \quad (7)$$

dimana :

- m = jumlah syaraf output
- $O_{p,k}$ = nilai output JST O_k pada pola ke- p
- $T_{p,k}$ = nilai target T_k untuk pola ke- p
- N = jumlah data

Dengan Fungsi kendala (*constraint function*) yang dapat ditulis sebagai berikut:

$$O_{p,k} = \sum_{j=1}^q z_j w_{jk} + b_k \quad (8)$$

$$z_j = \frac{1}{1 + \text{Exp} \left(-\sigma \left[\sum_{i=1}^n x_i w_{ij} + b_j \right] \right)} \quad (9)$$

dimana :

- w_{ij}, w_{jk}, b_j, b_k = variable bebas
- n = jumlah syaraf input (input node)
- q = jumlah syaraf tersembunyi (hidden node)
- σ = parameter kecuraman dari fungsi aktivasi
- k = jumlah yang dimodelkan = 1, ..., m

Keseluruhan proses pemodelan dikerjakan menggunakan program Excel. Khusus untuk proses pembelajaran dengan meminimumkan MSE (*Mean Square Error*) dipakai *tools* dari program Excel, yaitu *Premium Solver V.5*, yang mampu mengoptimasi fungsi-fungsi non linier dengan variable bebas yang banyak dalam waktu relatif singkat.

5. Penerapan Model NRECA dan ANN untuk DPS Cikapundung-Maribaya

Data debit dan data hujan bulanan yang tersedia di DPS Cikapundung-Maribaya sepanjang 30 tahun berturut-turut, dengan melibatkan 9 pos hujan yang tersebar di dalam dan di luar DPS. Model NRECA menggunakan tahun kalender dari Januari sampai dengan Desember hal ini tidak terlalu menjadi masalah karena ada perhitungan *antecedent soil*

moisture. Tidak demikian halnya dengan ANN karena model ini bersifat *black box* murni sehingga tidak ada perhitungan *soil moisture* dan untuk mengurangi pengaruh debit dari bulan sebelumnya terutama pada waktu awal perhitungan dipilih *water year* dari September sampai dengan Agustus tahun berikutnya.

Untuk kebutuhan penelitian (Adidarma et al.,1999) tahap kalibrasi dari model NRECA dibagi empat periode yaitu periode pertama dari tahun 1953-1959, kedua dari tahun 1960-1965, ketiga dari tahun 1971-1976 dan keempat dari tahun 1977-1982. Untuk model ANN, dilakukan juga pembagian yang sama tetapi berdasarkan *water year*.

Ada tiga jenis struktur yang telah dicoba, struktur pertama memperhatikan perilaku aliran di DPS dan sungai dengan memperhitungkan adanya antecedent soil moisture. (lihat **Gambar 2**, indeks Q pada input layer). Setiap bulan, diwakili oleh input layer (satu simpul hujan pada bulan yang bersangkutan dan 2 simpul debit dari bulan yang sebelumnya diambil dari hasil perhitungan), satu hidden layer dan satu output layer berupa debit pengamatan bulan yang bersangkutan. Struktur jaringan terdiri dari 12 set sub-struktur, lihat **Gambar 2**. Struktur jaringan kedua menjadikan hujan bulan September sampai dengan Agustus tahun berikutnya sebagai variabel input (12 simpul dari R) dan pada periode yang sama variabel output berupa debit bulanan (12 simpul dari Q) dalam mm, dilengkapi dengan 1 hidden layer dan tiga titik simpul, lihat **Gambar 3**. Untuk menjembatani tahun yang satu dengan tahun yang berikutnya dibuat tambahan satu simpul debit bulan Agustus hasil perhitungan menuju simpul hujan bulan September. Struktur terakhir, jaringan ketiga, sama dengan yang sebelumnya tetapi jumlah hidden layer ada dua dengan masing-masing 3 simpul. Dari hasil back-propagation terlihat bahwa faktor bobot dari simpul tambahan untuk struktur atau Pola 2 adalah 2,4 sedangkan pada Pola 3 menjadi nol. Hal ini dapat berarti untuk 2 hidden layer tidak diperlukan simpul tambahan, jembatan antara tahun yang satu dengan tahun yang lain sudah terbentuk dengan sendirinya.

6. Analisa dan Diskusi

Pemilihan 3 simpul pada hidden layer dengan maksimal 100 buah parameter yang perlu dicari sudah dapat dianggap mampu mempresentasikan proses hubungan hujan dan debit limpasan permukaan. Penambahan satu simpul pada hidden layer akan menambah paling sedikit 25 faktor bobot. Pola 1 membutuhkan 51 faktor bobot (w_{ij}), Pola 2 membutuhkan 78 faktor dan Pola 3, terbanyak 95 faktor, termasuk nilai α pada *activation function*

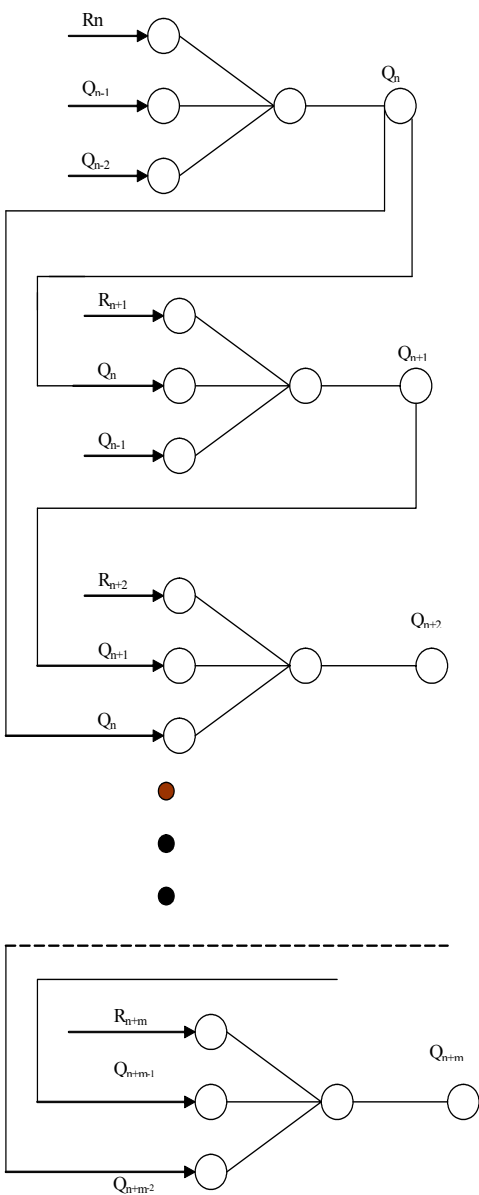
(tangen hiperbolis) dan faktor bobot untuk bias.

Pola 1 meskipun mengandung faktor bobot tersedikit tetapi karena strukturnya yang saling bergantung satu sama lain, lihat **Gambar 2** maka waktu yang dibutuhkan dalam proses propagation sangat lama dibandingkan dengan 2 pola yang lain. Lagipula, KAR yang dihasilkan oleh proses recall mencapai 0,6 sampai 0,7, oleh karena itu pola 1 untuk selanjutnya tidak digunakan. Nilai KAR untuk model NRECA berkisar antara 0,1 dan 0,39 dan model ANN menghasilkan KAR antara 0,16 sampai 0,34, lihat **Tabel 1 dan 2**. Model NRECA dikalibrasi berdasarkan periode yang ada dalam kolom pertama **Tabel 1**, periode selebihnya merupakan tahap verifikasi atau


recall pada model ANN, sedangkan pada **Tabel 2**, menunjukkan nilai KAR untuk tahap training dan recall untuk berbagai periode dari model ANN pola 2 dan 3.

Tabel 1. KAR dari model NRECA

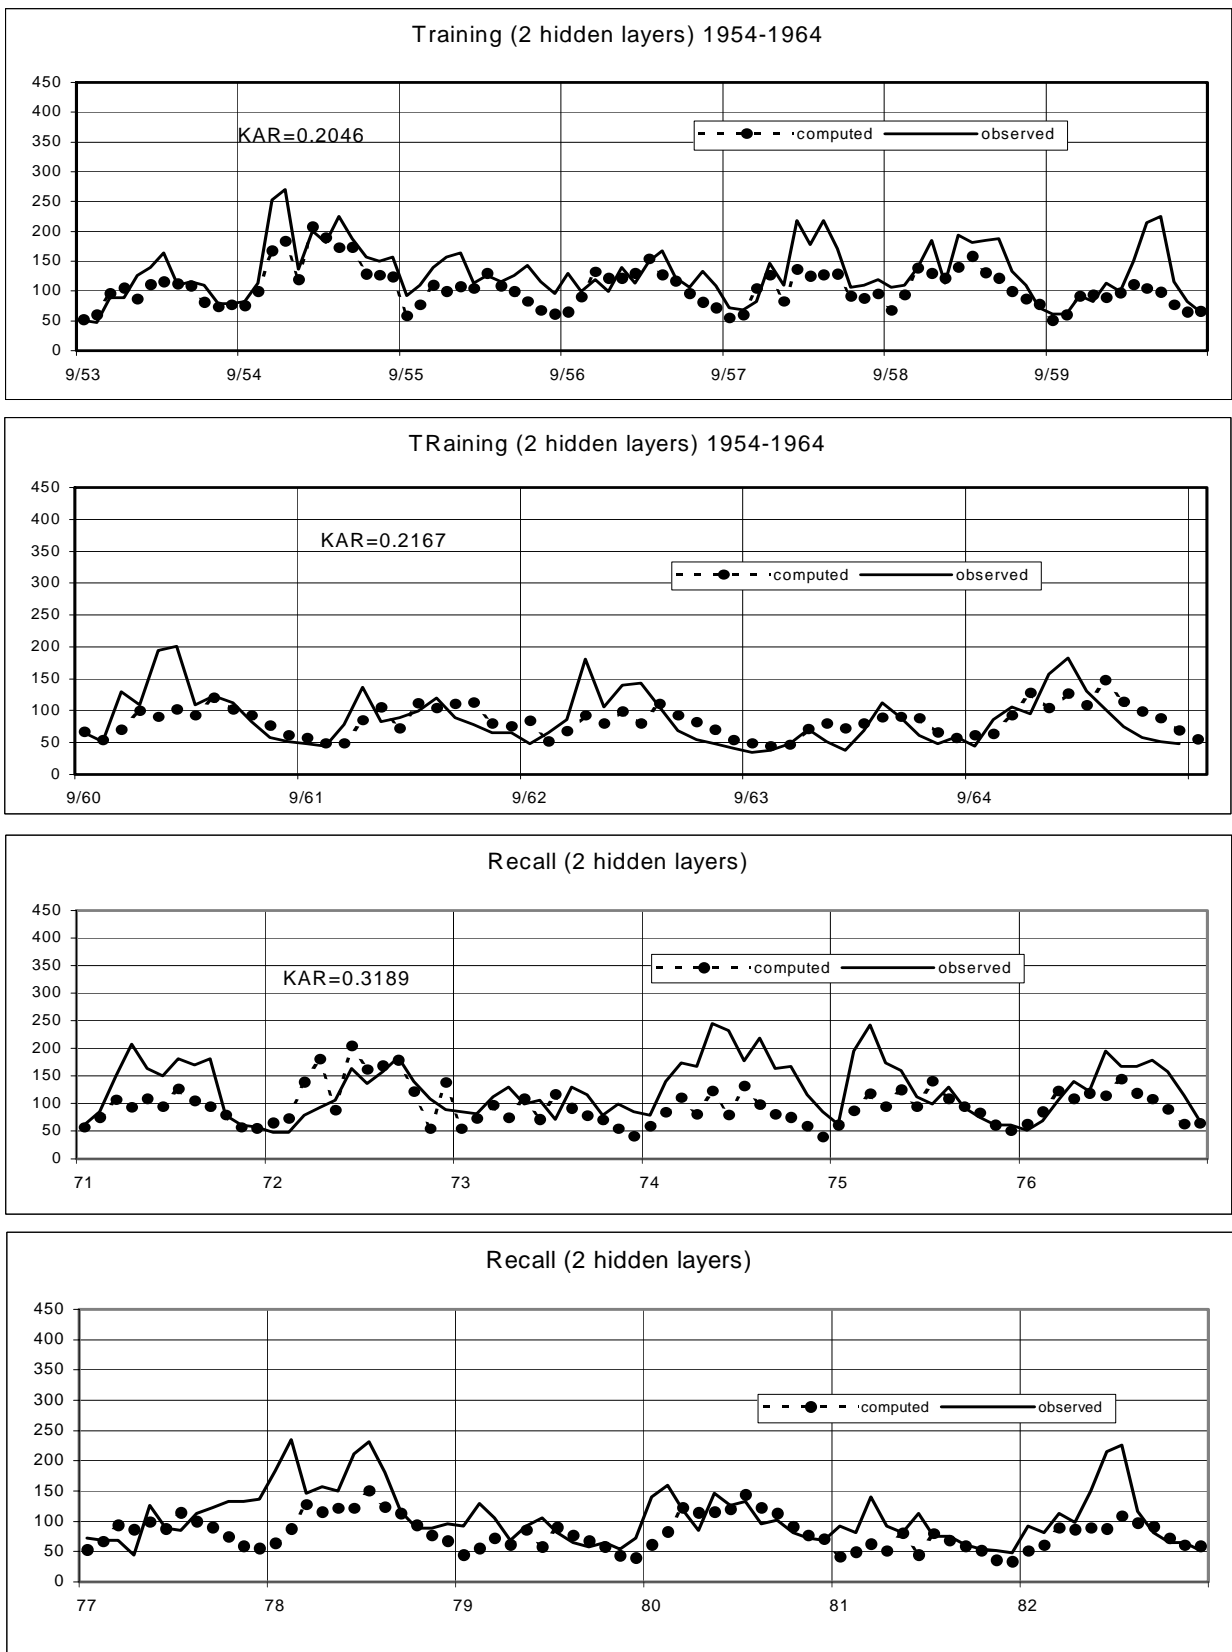
Kalibrasi	1953-1959	1960-1965	1970-1976	1977-1983	Total
1953-1959	0,1071	0,2216	0,2724	0,2012	0,8023
1966-1965	0,1511	0,1364	0,2986	0,2930	0,8791
1970-1976	0,1157	0,1885	0,2682	0,2171	0,7895
1977-1983	0,1612	0,3948	0,3180	0,1925	1,0665



Gambar 3. Struktur Jaringan Neural Pola-1



Gambar 4. Struktur jaringan neural pola-2



Gambar 5. Hasil rekonstitusi Model ANN (2 hidden layers)

Tabel 2. KAR dari model ANN

Pola	1953-1959	1960-1964	1971-1976	1977-1982	Total
2 (1 hidden)	0,2405	0,1613	0,3066	0,3416	1,0500
	0,2358	0,1640	0,3099	0,3365	1,0462
3(2 hidden)	0,2046	0,2167	0,3189	0,2766	1,0166
	0,2016	0,2334	0,3023	0,2739	1,0112
	0,1955	0,2431	0,3047	0,2641	1,0074

Catatan : Nilai yang berhuruf tebal,miring berarti periode yang mengalami Training

Tabel 3. Contoh proses optimisasi KAR untuk Pola-2

Tahap	tahun	Trail-1	Trail-2	Trial-3	Trial-4	Trial-5	Trail 6
Training	54-64	0,14	0,15	0,16	0,17	0,18	0,20
	53-59	0,2356	0,2182	0,2211	0,2314	0,2252	0,2405
	60-64	0,1579	0,1122	0,1313	0,1292	0,1707	0,1613
Recall	71-76	0,3271	0,3309	0,3367	0,3205	0,3442	0,3066
	77-82	0,3770	0,3772	0,3838	0,3653	0,3960	0,3416
Total		1.0976	1,0385	1,0729	1,0464	1,1361	1,050

Tinjauan KAR dari **Tabel 1 dan 2** memperlihatkan bahwa secara umum hasil kalibrasi NRECA lebih baik dari model ANN, hal ini lebih jelas terlihat pada **Gambar 4** Model dengan 2 hidden layers menghasilkan KAR yang sedikit lebih kecil, lihat kolom recall dan total (**kolom 6 Tabel 2**). Pemilihan nilai KAR optimum seperti terlihat dalam **Tabel 2**, dilakukan dengan cara coba-coba, nilai KAR minimum dapat dicapai dengan mudah pada tahap training, tetapi jika diterapkan pada recall nilai KAR-nya menjadi tinggi sekali, kasus ini disebut overfitting atau overtraining. **Tabel 3** di atas menunjukkan KAR dari setiap run, di mana KAR yang terbaik pada tahap training dicapai pada nilai 0,2405. Nilai ini didapat dengan menentukan $KAR=0,2$ pada tahap training, selanjutnya semua parameter digunakan oleh recall, pada tahap ini nilai faktor bobot bias pada output dirubah sehingga menghasilkan jumlah KAR (dari keempat periode) paling kecil. Pemilihan terakhir dilakukan dengan mempertimbangkan pula besaran KAR antara training dan recall agar tidak terlalu jauh.

Fungsi objektif yang seperti KAR dilakukan dengan pertimbangan penyimpangan terhadap data pengamatan menjadi pusat perhatian sehingga debit rendah menjadi lebih berarti. Hal ini dapat diperjelas dengan contoh sebagai berikut : Pada debit air rendah besarnya debit pengamatan 40 mm, debit perhitungan yang dihasilkan 80mm, penyimpangannya $60-40=20$ dan nilai $KAR(60-40)/40=0,5$. Pada air tinggi debit pengamatan mencapai 200mm perhitungan 300mm, selisihnya 100mm tetapi nilai KAR-nya sama yaitu sama dengan 0,5. Nilai KAR antara keduanya sama tetapi beda debitnya sangat berarti pada waktu rendah 20 mm dan pada waktu air tinggi 100mm. Jadi, nilai KAR untuk air rendah lebih peka daripada air tinggi.

Oleh karena itu jenis pengkalibrasian menggunakan KAR sangat sesuai untuk pengembangan sumber daya air yang lebih memperhatikan air rendah atau kritis.


Flow Dration Curve sering digunakan dalam perencanaan irigasi maupun air minum, bagian bawah mulai rata-rata, Q80%, Q90% atau bahkan debit minimum (Qmin) atau rata-rata minimum tahunan dapat menjadi dasar perencanaan untuk mengetahui sejauh mana ketersediaan air di lokasi yang bersangkutan. Di bawah ini akan disajikan ulasan mengenai hasil kedua model ditinjau dari debit rata-rata, debit handalan 80% dan 90% serta debit minimum, sebagai bentuk verifikasi lanjutan dari kedua model.

Berdasarkan hasil penelitian terdahulu terlihat untuk KAR lebih dari 0,20 (lihat **Tabel 1**) simpangan terhadap pengamatan dari rata-rata, debit handalan 80% dan debit minimum sekitar 1% sampai $\pm 40\%$. Sebagai gambaran untuk periode pertama (1953-1959) perbedaan antara debit rata-rata, debit handalan 80% dan Qmin pengamatan dan hasil perhitungan NRECA (kolom kedua **Tabel 1**, ada empat run) berada antara 0 sampai 20%, jadi cukup baik. Periode kedua (1960-1965), hanya 60% yang perbedaannya kurang dari 20%, periode ketiga (1971-1976) hanya 20% yang perbedaannya berada di bawah 20% dan periode keempat 60%nya perbedaan antara debit rata-rata, debit handalan 80% dan minimum dari empat run di kolom kelima **Tabel 1**, berada di bawah 20%.

Tahap training dan recall dari Model ANN menghasilkan debit rata-rata, debit handalan 80% dan 90% serta debit rata-rata dari minimum tahunan yang diperbandingkan dengan debit pengamatannya, ringkasannya dapat dilihat pada **Tabel 4**.

Tabel 4. Perbedaan terhadap pengamatan dari debit rata-rata, 80%, 90% dan minimum hasil Model ANN

	Pola/training	3/54-64	3/60-64	3/53-59	2/54-64	2/60-64
	1953-1964					
Mean		-14,61	-13,34	-13,07	-16,60	-18,12
Q80%		4,64	8,10	9,02	5,17	7,55
Q90%		13,46	17,78	19,45	16,21	13,58
Qmin		-9,31	-1,95	-2,90	9,98	6,10
	1971-1982					
Mean		-24,00	-21,26	-22,00	-14,43	-13,45
Q80%		-17,39	-10,79	-11,70	3,50	4,75
Q90%		-14,43	-6,62	-7,20	7,72	8,55
Qmin		-17,16	-9,20	-9,34	20,02	19,00



Gambar 6. KAR dari Model NRECA dan ANN

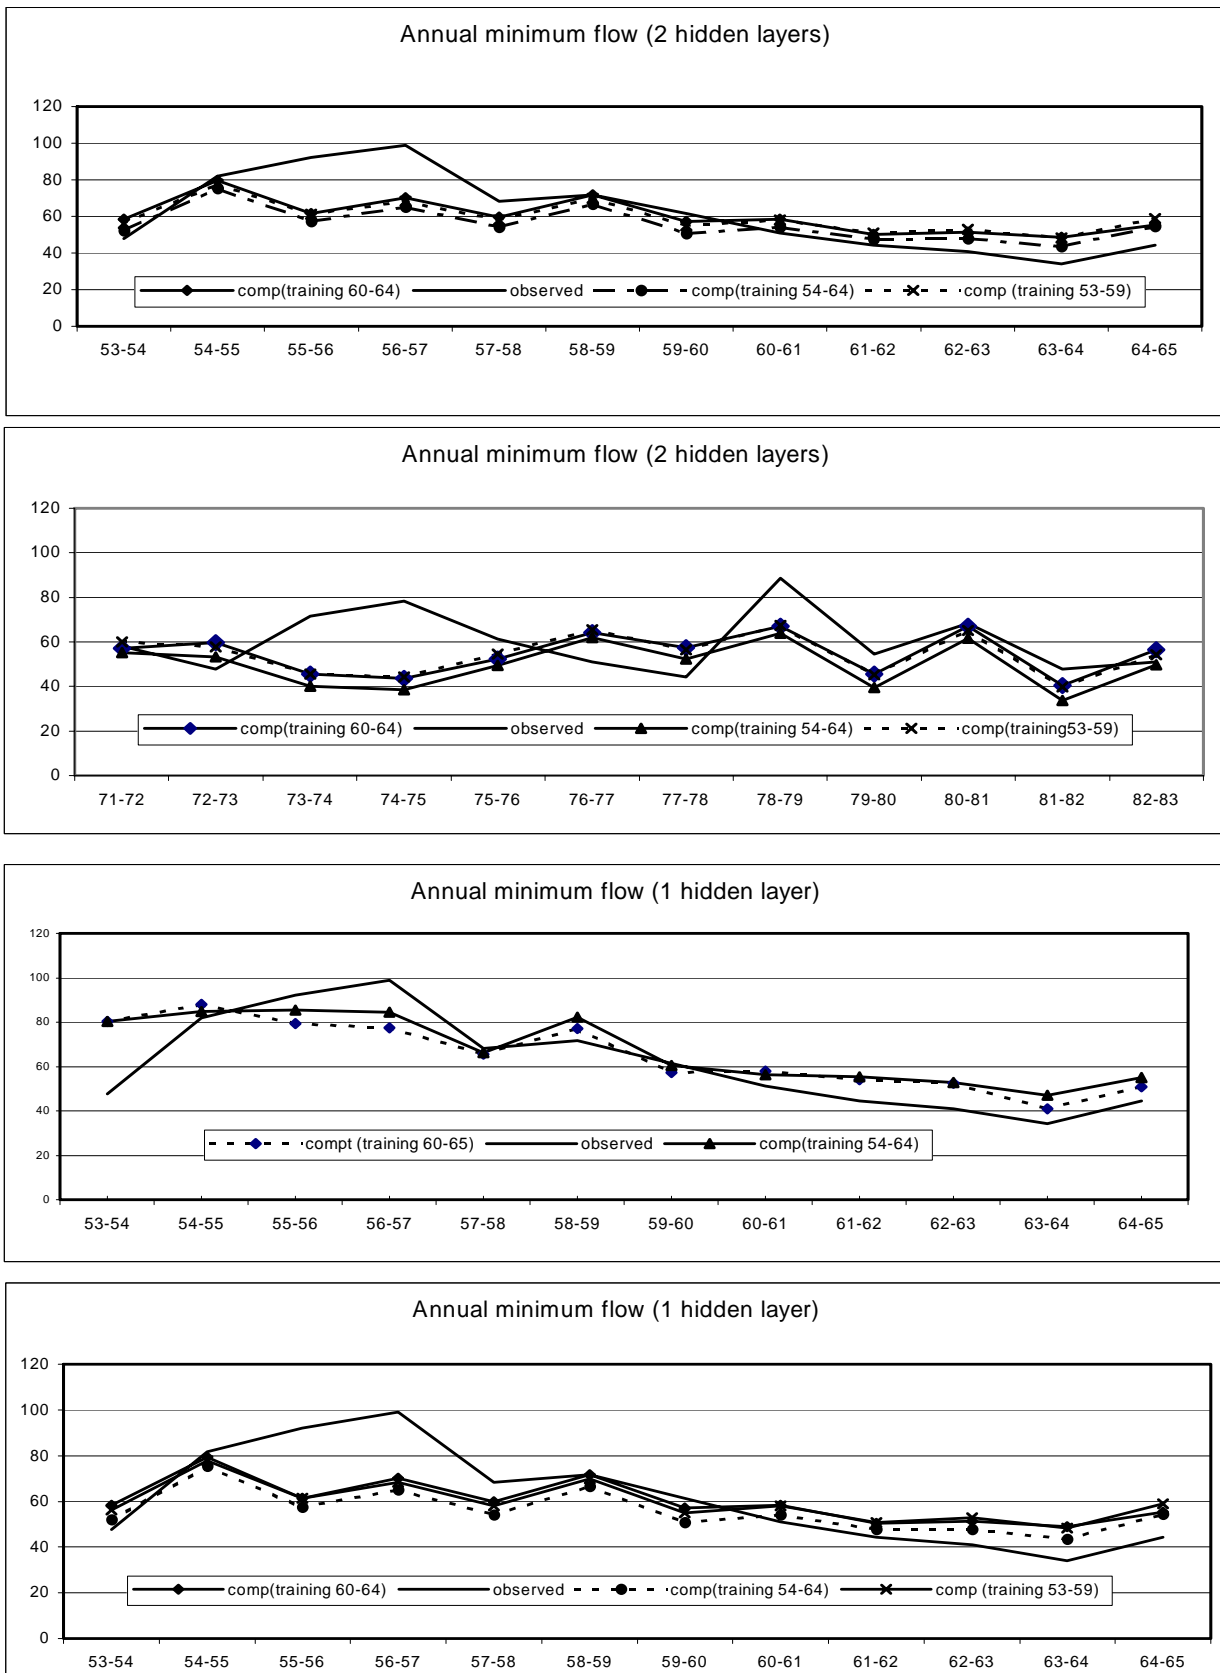
Penyimpangan lebih dari 20% (21%-24%) hanya dimiliki oleh rata-rata dari semua Pola 3, pada tahap recall lihat **Tabel 3**. Peta kondisi bagian bawah *Flow Duration Curve* dari Model ANN lebih baik dari model NRECA. Nilai maksimal penyimpangan dari ANN hanya mencapai 24%, sedang NRECA mendekati 80% (2 kasus Qmin dan debit rata-rata dari periode ke dua NRECA). Dari penjelasan di atas terlihat bahwa 50% dari perhitungan (debit rata-rata, 80% dan minimum) dari 48 run mempunyai penyimpangan di atas 20%.

Model dengan 1 hidden layer lebih baik bila ditinjau dari *Flow Duration Curve*, hanya di bagian bawah

menaik (lihat baris terakhir dari 2 kolom terakhir **Tabel 3**). Kondisi menaik dari debit minimum dapat dilihat secara rinci pada **Gambar 7**. Penyimpangan terbesar terjadi pada tahun-tahun di mana data debit pengamatan kosong, pada NRECA kekosongan ini tidak diperhitungkan dalam KAR.

7. Penutup

Secara umum, ANN dapat diterapkan dalam pemodelan hujan-limpasan yang hasilnya walaupun tidak terlalu akurat oleh karena masih terjadi penyimpangan sebesar lebih kurang 20%. Hal ini, mungkin disebabkan adanya pengambilan sumber air



Gambar 7. Minimum Flow setiap tahun dengan berbagai struktur model JST

yang tidak di pertimbangkan dalam pemodelan tersebut, yang menyebabkan kondisi alamiah (natural condition) sudah mulai terganggu dengan adanya pengambilan sumber air misalnya air baku. Selain itu, kesalahan pencatatan data atau adanya data yang kosong (hilang atau tidak tercatat) akan dapat pula memberikan kecenderungan hasil pembelajaran ANN yang tidak kurang akurat. Namun demikian, untuk kemungkinan kesempurnaan hasil pada penelitian selanjutnya, dapat diupayakan pengembangan tipe arsitektur ANN yang lain yang barangkali lebih sesuai dengan permasalahan tersebut.

Daftar Pustaka

- Adidarma W., Martawati L., 1999, “*Verifikasi Parameter NRECA*”, Prosiding Pertemuan Ilmiah Tahunan (PIT) XVI, Himpunan Ahli Teknik Hidraulik Indonesia (HATHI), Bengkulu, 25-26 Oktober.
- Darman F Saragih, Iwan K. Hadihardaja, 2003, “*Pemodelan Multivariant Deret Waktu Sumberdaya Air Menggunakan Jaringan Saraf Buatan*”, Jurnal Pengembangan Keairan, Badan Penerbit UNDIP, No.1 Tahun 10 Juli 2003 ISSN : 0845 - 4549
- Fleming, G., 1977, “*Computer Simulation Techniques in Hydrology*”, Elsevier, New York.
- Iwan K. Hadihardjaja, “*Model Pengoperasian Waduk Tunggal dengan Jaringan Syaraf Tiruan*”, Jurnal & Pengembangan Keairan, Badan Penerbit UNDIP, No.2,
- Kusumawati, D. I, 2001, “*Mencegah Overfitting pada Pemodelan Hujan-Aliran Menggunakan Artificial Neural Networks (ANN)*”, Kongres VII dan PIT (Pertemuan Ilmiah Tahunan) XVIII, Himpunan Ahli Teknik Hidraulik Indonesia (HATHI), Malang 22-24 Oktober 2001.
- Raman H., Sunilkumar, N., 1995, “*Multivariate Modelling of Water Resources Time Series Using Artificial Neural Networks*”, Journal of Hydrological Sciences, Volume 40, Number 2, IAHS Press, Wallingford, Tahun 10-Desember 2003 ISSN: 0854-4549
- Tsoukalas, L.H, Uhrig, R.E, 1997, “*Fuzzy and Neural Approaches in Engineering*”, John Wiley & Sons, INC, Singapore.

