

IMPLEMENTASI JARINGAN SYARAF TIRUAN *RECURRENT* DENGAN METODE PEMBELAJARAN *GRADIENT DESCENT* *ADAPTIVE LEARNING RATE* UNTUK PENDUGAAN CURAH HUJAN

Afan Galih Salman

Jurusan Teknik Informatika, Fakultas Ilmu Komputer, Universitas Bina Nusantara
Jl K.H. Syahdan No.9 Palmerah Jakarta Barat 11480
asalman@binus.edu

ABSTRAK

Penggunaan teknologi di bidang *Artificial Intelligence* khususnya teknologi Jaringan Syaraf Tiruan (JST) dalam pendugaan curah hujan dapat dilakukan dengan metoda pendekatan pembelajaran. Berdasarkan kemampuan belajar yang dimilikinya, maka JST dapat dilatih untuk mempelajari dan menganalisa pola data masa lalu dan berusaha mencari suatu formula atau fungsi yang akan menghubungkan pola data masa lalu dengan keluaran yang diinginkan pada saat ini. Keakuratan hasil prediksi JST diukur berdasarkan koefisien determinasi (R^2) dan *Root Mean Square Error* (RMSE).

Penelitian ini menerapkan jaringan syaraf tiruan *Recurrent Elman* yang teroptimasi secara heuristik untuk pendugaan curah hujan berdasarkan peubah *El-Nino Southern Oscillation* (ENSO) seperti Angin, , *Southern Oscillation Index* (SOI), *Sea Surface Temperatur* (SST) dan *Outgoing Long Wave Radiation* (OLR) dengan studi kasus daerah Bongan Bali.

Optimasi pembelajaran heuristik yang dilakukan pada dasarnya adalah pengembangan kinerja algoritma pembelajaran *gradient descent standard* menjadi algoritma pelatihan yaitu : *gradient descent adaptive learning rate*. Pola input data yang digunakan sangat berpengaruh terhadap kinerja JST *Recurrent Elman* dalam melakukan proses pendugaan. Kelompok data pertama yaitu 75% data pelatihan & 25% data uji menghasilkan R^2 maksimum 69,2% untuk leap 0 sedangkan kelompok data kedua yaitu 50% data pelatihan & 50% data uji menghasilkan R^2 maksimum 53,6 % untuk leap 0. Hasil nilai R^2 pada leap 0 lebih baik dibandingkan pada leap 1, leap 2 dan leap 3.

Kata Kunci : Jaringan Syaraf Tiruan *Recurrent Elman*, ENSO, Koefisien Determinasi (R^2), *Root Mean Square Error* (RMSE), *Gradient Descent Adaptive Learning Rate*.

1. PENDAHULUAN

1.1 Latar Belakang

Pendugaan curah hujan di sektor pertanian kini telah menjadi kebutuhan utama, seperti halnya pemilihan bibit, pupuk, dan pemberantas hama. Informasi tentang banyak curah hujan sangat berguna bagi petani dalam mengantisipasi peristiwa-peristiwa ekstrem seperti kekeringan dan banjir. Oleh karena itu dibutuhkan pendugaan curah hujan yang cepat dan akurat.

Dengan menggunakan sistem komputasi di bidang *Artificial Intelligence*, yaitu Jaringan Syaraf Tiruan (JST), maka identifikasi pola data dari sistem pendugaan curah hujan dapat dilakukan dengan metoda pendekatan pembelajaran. Berdasarkan kemampuan belajar yang dimilikinya, maka JST dapat dilatih untuk mempelajari dan menganalisa pola data masa lalu dan berusaha mencari suatu formula atau fungsi yang akan menghubungkan pola data masa lalu dengan keluaran yang diinginkan pada saat ini. Keakuratan hasil prediksi JST diukur berdasarkan koefisien determinasi (R^2) dan *Root Mean Square Error* (RMSE).

Model-model pendugaan curah hujan yang telah dilakukan selama ini belum banyak yang menggunakan data peubah *El-Nino Southern*

Oscillation (ENSO) sebagai masukan model JST padahal peubah ENSO cukup berpengaruh terhadap tinggi rendahnya curah hujan di sebagian besar wilayah Indonesia (Yusmen 1998). Penelitian yang pernah dilakukan sebelumnya hanya menggunakan data suhu dan curah hujan sebagai masukan model JST, diantaranya adalah penerapan metode *Principal Component Regression* (Fitriadi, 2004:1) menghasilkan R^2 sebesar 63,16%, JST propagasi balik standar (Normakristagaluh, 2004:1) menghasilkan R^2 sebesar 74,02%, JST propagasi balik standar menghasilkan R^2 sebesar 48,179% (Apriyanti, 2005:1) dan JST dengan optimasi algoritma genetika menghasilkan R^2 sebesar 87,7% (Apriyanti, 2005:1). Berdasarkan hal tersebut penelitian di bidang ini masih layak dan perlu dilakukan untuk mendapatkan model pendugaan curah hujan yang lebih akurat.

Dalam penelitian ini digunakan JST *recurrent* yang teroptimasi secara heuristik. Keunikan JST *recurrent* adalah adanya koneksi umpan balik yang membawa informasi gangguan (*noise*) pada saat masukan sebelumnya yang akan diakomodasikan bagi masukan berikutnya. Hal ini dapat meningkatkan kinerja JST *recurrent* khususnya dalam mengidentifikasi pola peubah ENSO terhadap

pendugaan curah hujan. Data peubah ENSO yang digunakan yaitu : *wind*, *Southern Oscillation Index* (SOI), *Sea Surface Temperatur* (SST) dan *Outgoing Long Wave Radiation* (OLR)

Optimasi heuristik adalah pengembangan dari suatu analisa kinerja pada algoritma *gradient descent standard* yang terdiri dari tiga algoritma pelatihan yaitu : *gradient descent adaptive learning rate*, *gradient descent adaptive learning rate & momentum* serta *resilient backpropagation*.

1.2 Tujuan Penelitian

Penelitian ini bertujuan mengembangkan model JST *recurrent* yang teroptimasi secara heuristik *gradient descent adaptive learning rate*, untuk pendugaan curah hujan berdasarkan peubah ENSO.

1.3 Ruang Lingkup Penelitian

- Model yang digunakan dalam penelitian ini dibatasi pada JST *recurrent* tipe Elman.
- Optimasi pembelajaran yang dilakukan dengan menggunakan teknik heuristik yaitu :, *gradient descent adaptive learning rate*.
- Data curah hujan berasal dari Balai Penelitian Agroklimat & Hidrologi (BALITKLIMAT) Bogor dan data ENSO berasal dari Lembaga Internasional seperti National Weather Service Center for Environmental Prediction Climate (NOAA).
- Data masukan hanya terdiri dari peubah ENSO dan target data curah hujan sehingga faktor-faktor pengaruh curah hujan lainnya tidak diperhitungkan.
- Model penelitian terbatas untuk daerah Bongan Bali.

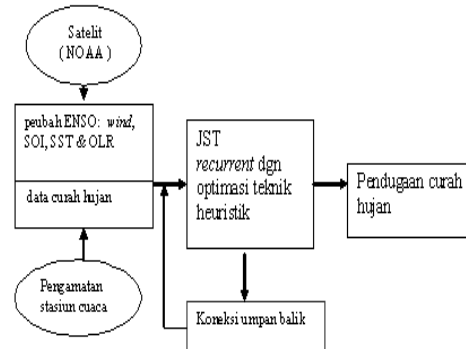
1.4 Manfaat Penelitian

Model JST *recurrent* yang diperoleh nantinya diharapkan dapat lebih meningkatkan keakuratan dan kecepatan dalam pendugaan curah hujan khususnya di wilayah Indonesia dengan menggunakan peubah-peubah ENSO dan membuka jalan bagi pengembangan penelitian di bidang yang sama dengan jumlah peubah yang berbeda.

1.5 Blok Diagram Sistem

JST *recurrent* adalah jaringan yang mengakomodasi keluaran jaringan untuk menjadi input pada jaringan itu lagi dalam rangka menghasilkan keluaran jaringan berikutnya. Pada penelitian ini digunakan jaringan JST *recurrent* tipe Elman. Jaringan ini dapat terdiri dari satu atau lebih lapisan tersembunyi, lapisan pertama memiliki bobot-bobot yang diperoleh dari lapisan input, setiap lapisan akan menerima bobot dari lapisan sebelumnya. Jumlah *neuron* dan lapisan tersembunyi disesuaikan dengan kompleksitas permasalahan. *Delay* yang terjadi pada hubungan antara lapisan

input dengan lapisan tersembunyi pertama pada waktu sebelumnya (t-1) dapat digunakan untuk saat ini (t). Blok diagram sistem proses pemodelan JST dalam pendugaan curah hujan berdasarkan peubah ENSO disajikan pada Gambar 1.



Gambar 1. Blok Diagram Pemodelan

2. LANDASAN TEORI

2.1 Pendugaan Curah Hujan

Pendugaan curah hujan di sektor pertanian kini telah menjadi kebutuhan utama, seperti halnya pemilihan bibit, pupuk, dan pemberantas hama. Informasi curah hujan bahkan menjadi acuan dalam memilih jenis bibit, waktu tanam dan jumlah stok bahan pangan pokok yang harus disediakan untuk memenuhi kebutuhan masyarakat. Bila dugaan tentang datangnya awal musim, termasuk sifat hujan dan periode musim meleset jauh, dampaknya bisa berupa kerugian besar bagi petani karena gagal panen dan kelangkaan pangan (Yusmen, 1998: 4).

Pendugaan curah hujan juga menjadi faktor penting di sektor pengairan atau pengelolaan daerah aliran sungai dalam kaitannya dengan sistem peringatan dini ketika terjadi banjir. Informasi curah hujan yang akurat, sangat penting bagi masyarakat khususnya yang berada di kawasan rawan banjir di bantaran sungai atau di daerah cekungan sehingga proses evakuasi dapat dilakukan lebih awal dan kerugian material serta korban jiwa dapat dihindari.

Curah hujan di Indonesia hampir seluruhnya dipengaruhi ENSO. ENSO adalah istilah yang terdiri dari dua fenomena yaitu El Nino merupakan fenomena lautan dan Southern Oscillation merupakan fenomena atmosfer. Istilah ENSO tidak begitu populer di kalangan media massa, istilah El Nino-lah yang sering dipakai. Peubah ENSO yang umumnya digunakan adalah SOI yaitu perbedaan antara nilai indeks tekanan udara di Tahiti dan Darwin, dan SST yaitu nilai anomali suhu permukaan laut, selain peubah lainnya *wind* dan OLR. Pemanasan suhu muka laut di sebelah barat Samudra Pasifik menimbulkan gangguan cuaca ENSO, yaitu berdampak kurangnya curah hujan di kawasan timur Pasifik termasuk Indonesia. Sebaliknya ketika pemanasan terjadi di timur Pasifik disebut anomali cuaca La Nina, hujan yang tinggi

terjadi di wilayah tersebut (Lakshmi Sri et al. 2003:4).

Daerah di Indonesia yang bakal terpengaruh El Nino atau La Nina adalah Papua, Maluku, Sulawesi, sebagian besar Sumatera, Sumatera Selatan, seluruh Pulau Jawa, Kalimantan Barat, Kalimantan Tengah, Kalimantan Selatan, Kalimantan Timur, Sulawesi, Maluku, Bali, Nusa Tenggara, dan Irian Jaya. Sementara daerah yang tidak terpengaruh oleh ENSO adalah Aceh, Sumatera Utara, Sumatera Barat, Riau, Jambi dan Bengkulu. Pengaruh ENSO yang paling kuat terjadi pada tahun 1987-1988. Prakiraan cuaca mengenai terjadinya kekeringan karena El Nino sebenarnya tidak dapat dipukul rata akan terjadi di seluruh wilayah Indonesia. Di wilayah Pare-Pare dan Sulawesi Selatan dapat terjadi empat gangguan cuaca dengan pola yang berbeda (Effendy 2001:1).

Berdasarkan hal tersebut di atas maka prakiraan cuaca di Indonesia tidak bisa diberlakukan secara umum, apalagi di negeri yang luas ini terbagi tiga tipe cuaca, yaitu ekuatorial, monsun dan lokal. Di wilayah dengan pola cuaca tersebut, datangnya musim kemarau dan hujan sepanjang tahun akan berbeda-beda, bahkan berkebalikan. Melihat fenomena tersebut maka di masa mendatang Indonesia perlu mengembangkan model pendugaan curah hujan sendiri karena wilayah Indonesia yang berada di antara dua benua dan dua samudera merupakan daerah yang memiliki karakteristik iklim dan cuaca yang tiada duanya di dunia (Yusmen 1998:4).

2.2 Jaringan Syaraf Tiruan

Peniruan cara berpikir otak manusia dengan menggunakan sistem komputer telah memberi inspirasi kepada para ilmuwan pada abad ini. Dimulai sejak lima puluh tahun yang lalu, ilmuwan telah menciptakan model perangkat elektronik pertama dari sel-sel syaraf. Semenjak itu banyak komunitas ilmuwan bekerja dalam model matematika baru ini beserta algoritma-algoritma pembelajaran. Sekarang, model itu lebih dikenal dengan nama jaringan syaraf tiruan. Jaringan syaraf tiruan menggunakan sejumlah unit komputasi sederhana yang disebut *neuron*, yang berusaha meniru perilaku sel tunggal otak manusia. Otak manusia sendiri mengandung 10 milyar sel – sel syaraf dengan sekitar 10000 *synapses*. *Neuron-neuron* biologis memancarkan sinyal elektrokimia pada jalur-jalur syaraf, yang terdiri atas bagian *body*, *axon* dan *dendrit*. Sinyal datang melalui *dendrit*, diolah oleh *body* dan dihantarkan melalui *axon*. Sel itu sendiri mengandung *kernel* dan bagian luarnya *membrane* elektrik. Setiap *neuron* mempunyai level aktivasi, dengan *range* diantara maksimum dan minimum. Setiap *neuron* menerima sinyal-sinyal dari *neuron* lain melalui sambungan khusus *synapses* yang berfungsi untuk memperbesar dan memperkecil aktivasi *neuron* terhadap *neuron*

lainnya. *Synapses* ini membawa level aktivasi dari *neuron* pengirim ke *neuron* penerima .

JST merupakan system pemrosesan informasi yang memiliki karakteristik serupa dengan jaringan syaraf biologis dengan ciri-ciri:

1. Pola hubungan antara elemen-elemen sederhana yakni *neuron*.
2. Metode penentuan bobot koneksi.
3. Fungsi aktivasinya.

JST mempunyai sifat dan kemampuan:

- a. Akuisisi pengetahuan di bawah derau (*noise*) dan ketidakpastian (*uncertainty*).
- b. Representasi pengetahuan yang fleksibel.
- c. Pemrosesan pengetahuan yang efisien.
- d. Toleransi kesalahan, dengan representasi pengetahuan terdistribusi dan pengkodean informasi yang redundan, kinerja system tidak menurun drastic berkaitan dengan responnya terhadap kesalahan (Workshop JNB, 2002:6).

2.3 Jaringan Syaraf Tiruan Propagasi Balik.

Model *neuron* yang pertama diperkenalkan pada tahun 1943 oleh McCulloch dan Pitts. Hebb pada tahun 1949 mengusulkan sebuah aturan pembelajaran yang menjelaskan bagaimana sebuah jaringan sel-sel syaraf belajar. Kemudian Rosenblatt pada tahun 1958 menemukan algoritma pembelajaran *perceptron*, serta Widrow dan Hoff mengusulkan *varian* dari pembelajaran *perceptron* yang disebut aturan Widrow-Hoff. Kemudian pada tahun 1969, Minsky dan Papert menunjukkan keterbatasan teoritis dari jaringan neural lapis tunggal (*single layer neural networks*) sehingga menyebabkan penurunan riset di bidang ini. Tetapi pada tahun 1980-an pendekatan JST hidup kembali dimulai oleh Hopfield yang memperkenalkan ide minimasi energi dalam fisika ke dalam JST. Pada pertengahan dekade tersebut algoritma propagasi balik (*backpropagation*) yang dikembangkan Rumelhart, Hinton dan Williams memberikan pengaruh besar tidak hanya bagi riset-riset JST tetapi juga bagi ilmu komputer, kognitif dan biologi yang lebih luas. Algoritma ini menawarkan solusi untuk pembelajaran JST lapis banyak (*multi-layer neural networks*) sehingga dapat mengatasi keterbatasan jaringan syaraf lapis tunggal .

Prinsip dasar algoritma *backpropagation* memiliki tiga tahap :

- Tahap *feedforward* pola input pembelajaran
- Tahap kalkulasi dan *backpropagation error* yang diperoleh.
- Tahap penyesuaian bobot.

Arsitektur yang digunakan adalah jaringan *perceptron* lapis banyak (*multi-layer perceptrons*). Hal ini merupakan generalisasi dari arsitektur *perceptron* lapis tunggal (*single layer perceptron*). Secara umum, algoritma jaringan ini membutuhkan waktu pembelajaran yang memang lambat, tetapi setelah pembelajaran dan pelatihan selesai,

aplikasinya akan memberikan *output* yang sangat cepat (Workshop JNB 2002).

2.3.1 Optimasi Pembelajaran Heuristik

Pada JST *backpropagation* dikenal optimasi teknik heuristik yaitu algoritma pelatihan yang berfungsi untuk lebih mempercepat proses pelatihan dan merupakan pengembangan dari suatu analisa kinerja pada *algoritma steepest (gradient) descent standard*.

2.3.2 Gradient Descent Adaptive Learning Rate.

Teknik heuristik ini memperbaiki bobot berdasarkan *gradient descent* dengan laju pembelajaran yang bersifat *adaptive*. Pada *gradient descent standard*, selama proses pembelajaran, laju pembelajaran (α) akan terus bernilai konstan. Apabila laju pembelajaran terlalu tinggi, maka algoritma menjadi tidak stabil. Sebaliknya, jika laju pembelajaran terlalu kecil maka algoritma akan sangat lama dalam mencapai kekonvergenan. Pada kenyataannya, nilai laju pembelajaran yang optimal akan terus berubah selama proses pelatihan seiring dengan berubahnya nilai fungsi kinerja. Pada *gradient descent adaptive learning rate*, nilai laju pembelajaran akan diubah selama proses pelatihan untuk menjaga agar algoritma ini senantiasa stabil selama proses pelatihan. Kinerja jaringan syaraf dihitung berdasarkan nilai *output* jaringan dan *error* pelatihan. Pada setiap epoch, bobot-bobot baru dihitung dengan menggunakan laju pembelajaran yang ada. Kemudian dihitung kinerja jaringan syaraf baru. Jika perbandingan kinerja syaraf baru dan kinerja syaraf lama melebihi maksimum kenaikan kerja (*max_perf_inc*), maka bobot baru tersebut akan diabaikan, dan nilai laju pembelajaran akan dikurangi dengan cara mengalikannya dengan parameter penurunan laju pembelajaran (*lr_dec*). Sebaliknya, apabila perbandingan kinerja syaraf baru dan kinerja syaraf lama kurang dari maksimum kenaikan kerja, maka nilai bobot-bobot akan dipertahankan, dan nilai laju pembelajaran akan dinaikkan dengan cara mengalikannya dengan parameter penambahan laju pembelajaran (*lr_inc*).

Langkah-langkah teknik heuristik ini adalah :

1. Hitung bobot dan bias baru lapisan *output* dengan menggunakan persamaan:

$$w_{jk}(\text{baru}) = w_{jk}(\text{lama}) + \Delta w_{jk}$$

$$b_{2k}(\text{baru}) = b_{2k}(\text{lama}) + \Delta b_{2k}$$
2. Hitung bobot dan bias baru lapisan tersembunyi dengan menggunakan persamaan :

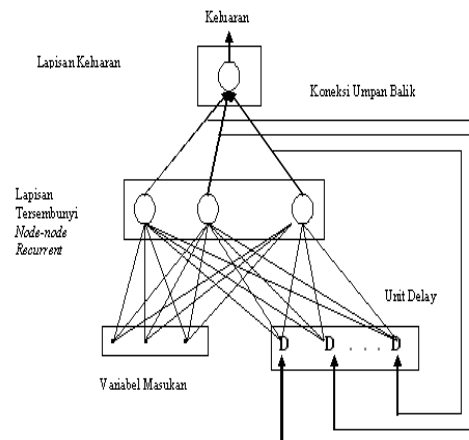
$$v_{ij}(\text{baru}) = v_{ij}(\text{lama}) + \Delta v_{ij}$$

$$b_{1j}(\text{baru}) = b_{1j}(\text{lama}) + \Delta b_{1j}$$
3. Hitung kinerja jaringan syaraf baru (*perf2*) dengan menggunakan bobot-bobot baru tersebut.
4. Bandingkan kinerja jaringan syaraf baru (*perf2*) kinerja jaringan syaraf sebelumnya (*perf*).

5. Jika $\text{perf2}/\text{perf} > \text{max_perf_inc}$ maka laju pembelajaran (α) = $\alpha * \text{lr_dec}$.
6. Jika $\text{perf2}/\text{perf} < \text{max_perf_inc}$ maka laju pembelajaran (α) = $\alpha * \text{lr_inc}$.
7. Jika $\text{perf2}/\text{perf} \leq \text{max_perf_inc}$ maka bobot baru diterima sebagai bobot sekarang (Kusumadewi,2004:150).

2.4 Jaringan Syaraf Tiruan Recurrent Elman

JST *recurrent* adalah jaringan yang mengakomodasi keluaran jaringan untuk menjadi masukan pada jaringan itu lagi dalam rangka menghasilkan keluaran jaringan berikutnya. Jaringan *recurrent* Elman terdiri atas satu atau lebih lapisan tersembunyi. Lapisan pertama memiliki bobot-bobot yang diperoleh dari lapisan *input*, setiap lapisan akan menerima bobot dari lapisan sebelumnya. Jaringan ini biasanya menggunakan fungsi aktivasi *sigmoid bipolar* untuk lapisan tersembunyi dan fungsi linear (*purelin*) untuk lapisan keluaran. Tidak seperti pada *backpropagation*, pada jaringan Elman ini, mempunyai fungsi aktivasi yang dapat berupa sembarang fungsi, baik yang kontinu maupun diskontinyu. *Delay* yang terjadi pada hubungan antara lapisan input dengan lapisan tersembunyi pertama pada waktu sebelumnya (*t-1*) dapat digunakan untuk saat ini (*t*) Keunikan JST *recurrent* adalah adanya koneksi umpan balik yang membawa informasi gangguan (*noise*) pada saat masukan sebelumnya yang akan diakomodasikan bagi masukan berikutnya.



Gambar 2. Arsitektur JST Recurrent

2.5 Inisialisasi Nguyen-Widrow.

Inisialisasi ini umumnya mempercepat proses pembelajaran dibandingkan dengan inisialisasi acak.

Inisialisasi Nguyen-Widrow didefinisikan sebagai persamaan berikut:

- a. Hitung harga faktor pengali β

$$\beta = 0.7 p^{1/n}$$

Dimana :

β = Faktor pengali.

n = Jumlah *neuron* lapisan input.

- p = Jumlah neuron lapisan tersembunyi
- Untuk setiap unit tersembunyi ($j=1, 2, \dots, p$):
hitung v_{ij} (lama) yaitu bilangan acak antara -0.5 dan 0.5 (atau di antara $-\gamma$ dan sampai γ).
 - Hitung : $\| v_j \|$
Pembaharuan bobot v_{ij} (lama) menjadi v_{ij} (baru) yaitu :

$$v_{ij}(\text{lama}) = \frac{\beta v_{ij}(\text{lama})}{\| v_j(\text{lama}) \|}$$
 - Set bias :
 B_{1j} = Bilangan random antara $-\beta$ sampai β .

2.5 Ketepatan Pendugaan

Ketepatan pendugaan sebuah model regresi dapat dilihat dari koefisien determinasinya (R^2) dan *Root Mean Square Error* (RMSE). Nilai R^2 menunjukkan proporsi jumlah kuadrat total yang dapat dijelaskan oleh sumber keragaman peubah bebas, sedangkan RMSE menunjukkan besar simpangan nilai dugaan terhadap nilai aktualnya. R^2 adalah kuadrat dari korelasi antara nilai vektor observasi y dengan nilai vektor penduga \hat{y} .

Kecocokan model semakin baik jika R^2 mendekati 1 dan RMSE mendekati 0.

3. DATA & METODE PENELITIAN

3.1 Data

Data yang digunakan dalam penelitian ini adalah :

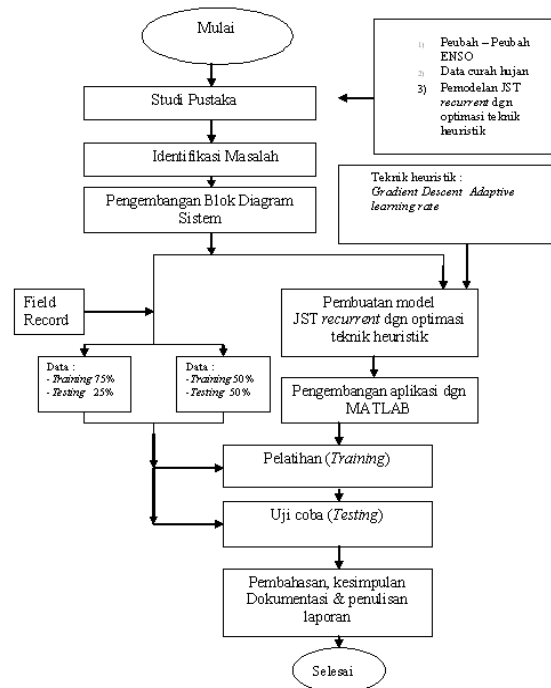
- Data ENSO
Data ini diperoleh dari lembaga internasional National Weather Service Center for Environmental Prediction Climate (NOAA) selama 83 bulan dengan domain cakupan data peubah ENSO ini adalah wilayah Nino-3,4 yaitu : $5^\circ \text{LU} - 5^\circ \text{LS}$ dan $90^\circ \text{BB} - 150^\circ \text{BB}$.
- Data Curah Hujan
Data curah hujan yang digunakan dalam penelitian ini adalah curah hujan rata-rata di daerah Bongan Bali selama 83 bulan dengan domain cakupan data $08^\circ 33' 05'' \text{S} - 115^\circ 05' 48'' \text{E}$ dengan ketinggian 124 meter yang diperoleh dari BALITKLIMAT Bogor.

3.2 Metode Penelitian

Penelitian diawali dengan studi pustaka yaitu mengidentifikasi peubah ENSO dan pengaruhnya terhadap curah hujan di wilayah Indonesia. Langkah berikutnya mempelajari penelitian-penelitian yang pernah dilakukan untuk mengetahui metoda yang digunakan dan ketepatan pendugaan yang telah dicapai.

Dari hasil studi pustaka diidentifikasi masalah yang ada, yaitu perlunya suatu pemodelan

pendugaan curah hujan yang lebih akurat khususnya berdasarkan peubah ENSO. Selanjutnya dikembangkan model *JST recurrent* yang dioptimasi secara heuristik. Metodologi selengkapnya disajikan pada Gambar 3.



Gambar 3. Metode Penelitian

4. PERANCANGAN & IMPLEMENTASI SISTEM

4.1 Desain Arsitektur.

Arsitektur yang digunakan adalah jaringan *recurrent* tipe Elman dengan 2 lapisan tersembunyi. Masukan terdiri dari data : *wind*, *SOI*, *SST* dan *OLR* dan target adalah data curah hujan. Pada saat proses penentuan arsitektur standar *JST recurrent*, dilakukan proses *trial & error* untuk mendapatkan unjuk kerja *JST* yg optimum dengan parameter :

- Dimensi jaringan (jumlah *neuron* dan *hidden layer*).
- Laju Pembelajaran (*learning rate*)

Algoritma pembelajaran yang digunakan adalah optimasi teknik heuristik *Gradient descent adaptive learning rate*.

Setiap proses pelatihan dan pengujian diulang sebanyak 20 kali untuk dicari nilai rata-rata dan simpangan bakunya. Hasil dari pengujian adalah tingkat keakuratan antara nilai dugaan dengan nilai aktual berdasarkan dua parameter yaitu R^2 dan RMSE. Nilai R^2 yang diperoleh dikalikan 100% untuk memudahkan pembacaan tingkat keakuratan.

4.2 Tahapan Penelitian

Dalam penelitian ini akan dikaji permodelan JST *recurrent* yang teroptimasi secara heuristik untuk pendugaan curah hujan berdasarkan peubah ENSO.

Tahapan permulaan, masing-masing kelompok data akan mengalami proses inialisasi dengan menggunakan metoda Nguyen-Widrow. Jumlah *neuron* dan *hidden layer* ditetapkan dengan percobaan pendahuluan secara *trial & error* dan merujuk pada penelitian-penelitian sebelumnya. Tahap berikutnya dilakukan percobaan yaitu :

- a. Langkah pertama dilakukan pembelajaran terhadap ke empat peubah ENSO dan curah hujan sebagai target, dengan menggunakan kelompok data pertama yaitu 75% data pelatihan dan 25% data pengujian.
- b. Langkah kedua dilakukan pembelajaran terhadap ke empat peubah ENSO dan curah hujan sebagai target, dengan menggunakan kelompok data kedua yaitu 50% data pelatihan dan 50% data pengujian.

Tabel 1. Arsitektur JST Recurrent Standar

Karakteristik	Spesifikasi
Arsitektur	2 lapisan tersembunyi
Neuron Input	Peubah ENSO & curah hujan
Neuron hidden layer 1	48
Neuron hidden layer 2	24
Neuron Output	1
Fungsi aktivasi <i>hidden layer</i> 1	Sig moid biner
Fungsi aktivasi <i>hidden layer</i> 2	Sig moid bipolar
Fungsi aktivasi <i>layer output</i>	Fungsi linier
Inialisasi bobot	Nguyen Widrow
Toleransi galat	0.01
Maksimum epoch	30.000
Laju pembelajaran	0,1
Maksimum kenaikan kinerja	1,06

Struktur standar untuk penelitian dengan menggunakan algoritma pembelajaran *gradient descent adaptive learning rate* seperti disajikan Komposisi percobaan yang dilakukan adalah terhadap komposisi nilai:

- lr_inc 1,20 & lr_dec 0,6
- lr_inc 1,05 & lr_dec 0,6
- lr_inc 1,05 & lr_dec 0,7

Pada setiap kelompok data dengan komposisi di atas dilakukan percobaan terhadap variasi *leap* yang berbeda-beda yaitu $leap = 0, 1, 2$, dan 3.

- *Leap* 0 pendugaan curah hujan jatuh pada bulan yang sama.
- *Leap* 1 pendugaan curah hujan jatuh pada satu bulan ke depan.
- *Leap* 2 pendugaan curah hujan jatuh pada dua bulan ke depan.

- *Leap* 3 pendugaan curah hujan jatuh pada tiga bulan ke depan.

Setiap percobaan dilakukan pengulangan/iterasi sebanyak 20 kali dengan tujuan memperoleh rata-rata R^2 dan RMSE yang memiliki simpangan baku terkecil. Nilai R^2 dan RMSE tiap kombinasi terletak pada selang nilai tertentu (minimum dan maksimum). Hasil percobaan pada penelitian ini difokuskan pada perbandingan ketepatan pendugaan JST menghasilkan R^2 maksimum dan RMSE minimum.

4.3 Desain Struktur Data

Desain struktur data berupa tabel data bulanan peubah-peubah ENSO & curah hujan seperti disajikan pada Tabel 2.

Tabel 2. Contoh Data Peubah ENSO & Curah Hujan

Bulan	Indeks OLR	Indeks WIND	Indeks SOI	Indeks SST	Curah Hujan (mm)
Januari	23,5	6,6	0,5	0,18	649,0
Februari	9,7	6,7	1,2	0,28	601,0
Maret	21,7	7,4	0,9	0,52	321,0
April	5,4	5,3	1,0	0,9	151,0
Mei	19,7	5,9	0,5	1,06	14,0
Juni	22,4	6,1	0,6	0,79	176,0
Juli	25,9	8,2	-0,2	0,48	121,0
Agustus	40,6	6,6	1,7	0,14	12,0
September	40,1	6,5	0,9	0,28	40,0
Oktober. dst	28,3	6,1	1,2	0,33	53,0

4.4 Desain Keluaran (Output)

Data keluaran berupa tabel hasil penelitian berupa nilai-nilai epoch, R^2 dan RMSE dari setiap kelompok data percobaan yang telah dilakukan juga dihitung nilai – nilai R^2 minimum, R^2 maksimum, rata-rata R^2 , standar deviasi R^2 , RMSE minimum, RMSE maksimum, rata-rata RMSE dan standar deviasi RMSE.

4.5 Perangkat Keras dan Lunak

Penelitian ini menggunakan perangkat keras dan lunak sebagai berikut:

- a. Intel Pentium IV 2,66 GHz
- b. Memori SDRAM 256 MB
hardisk 40 GB
- c. Matlab 7
- d. Microsoft Excel Xp Professional

5. HASIL DAN PEMBAHASAN

5.1 Komposisi Data Pelatihan & Pengujian

Komposisi data pelatihan & pengujian sangat berpengaruh terhadap keakuratan pendugaan dalam JST. Seperti yang dijelaskan dalam metodologi, data dibagi ke dalam 2 kelompok data percobaan yaitu kelompok data pertama, 75% data (62 bulan) pelatihan dan 25% data (21 bulan) pengujian serta kelompok data kedua 50% data (42 bulan) untuk pelatihan dan 50% data (41 bulan) untuk data pengujian. Masing-masing kelompok data akan dibahas dan diperlihatkan grafik hasil percobaan.

5.2 Kelompok Data Pertama.

Tabel 3. Kompilasi Hasil percobaan kelompok data pertama *gradient descent adaptive learning rate*

Komposisi <i>lr inc & lr dec</i>	Leap 0		Leap 1		Leap 2		Leap 3	
	R ² Maks	RMSE Min	R ² Maks	RMSE Min	R ² Maks	RMSE Min	R ² Maks	RMSE Min
1,05 & 0,6	63,4	265,70	65,1	174,41	59,8	211,42	51,9	170,00
1,05 & 0,7	64,5	213,96	65,9	183,78	64,1	210,48	53,1	285,4
1,20 & 0,6	69,2	238,11	66,5	173,05	61,6	206,85	55,5	156,83

5.3 Kelompok Data Kedua

Tabel 4. Kompilasi Hasil percobaan kelompok data kedua *gradient descent adaptive learning rate*

Komposisi <i>lr inc & lr dec</i>	Leap 0		Leap 1		Leap 2		Leap 3	
	R ² Maks	RMSE Min	R ² Maks	RMSE Min	R ² Maks	RMSE Min	R ² Maks	RMSE Min
1,05 & 0,6	46,0	244,31	46,0	198,13	29,0	269,44	6,54	305,09
1,05 & 0,7	47,3	272,50	46,4	200,82	32,4	277,55	8,75	314,85
1,20 & 0,6	53,6	297,69	45,7	197,55	28,4	269,45	12,6	344,63

5.4 Komposisi Parameter Terbaik

Topologi jaringan JST *recurrent* yang digunakan dalam penelitian ini berupa satu lapisan input, dua lapisan tersembunyi terdiri dari lapisan tersembunyi pertama dengan jumlah 48 *neuron* dan lapisan tersembunyi kedua dengan 24 *neuron* serta satu lapisan output dengan 1 *neuron*. Topologi ini sudah ditetapkan terlebih dahulu berdasarkan percobaan pendahuluan secara *trial & error*, tujuannya agar penelitian utama lebih berfokus pada parameter dari algoritma pembelajaran yang akan diterapkan.

5.5 Komposisi Parameter Terbaik Adaptive Learning Rate

Percobaan kelompok data pertama untuk *leap 0*, nilai parameter yang divariasikan adalah *lr inc* dan *lr dec*. Ketika nilai *lr inc* tetap 1,05 dan nilai *lr dec* dinaikkan dari 0,6 menjadi 0,7 hasilnya nilai R² maksimum naik dari 63,4 menjadi 64,5. Nilai rata-rata R² naik dari 31,4 menjadi 35,3 sedangkan nilai

RMSE turun dari 265,7 menjadi 213,96. Kemudian, nilai *lr inc* dinaikkan dari 1,05 menjadi 1,2 dan nilai *lr dec* diturunkan dari 0,7 menjadi 0,6 hasilnya nilai R² maksimum naik dari 64,5 menjadi 69,2. Nilai rata-rata R² turun dari 35,3 menjadi 28,4 sedangkan nilai RMSE naik dari 213,96 menjadi 238,11. Komposisi parameter terbaik percobaan kelompok data pertama untuk *leap 0*, adalah *lr inc* 1,2 dan *lr dec* 0,6.

Percobaan kelompok data kedua untuk *leap 0*. Ketika nilai *lr inc* tetap 1,05 dan nilai *lr dec* dinaikkan dari 0,6 menjadi 0,7 hasilnya nilai R² maksimum naik dari 46 menjadi 47,3. Nilai rata-rata R² turun dari 38,9 menjadi 38,4 sedangkan nilai RMSE naik dari 244,31 menjadi 272,5. Kemudian nilai *lr inc* dinaikkan dari 1,05 menjadi 1,2 dan nilai *lr dec* diturunkan dari 0,7 menjadi 0,6 hasilnya nilai R² maksimum naik dari 47,3 menjadi 53,6. Nilai rata-rata R² naik dari 38,4 menjadi 39,2 sedangkan nilai RMSE naik dari 272,5 menjadi 297,69. Komposisi parameter terbaik percobaan kelompok data kedua untuk *leap 0*, adalah *lr inc* 1,2 dan *lr dec* 0,6.

Percobaan kelompok data pertama untuk *leap 1*. Ketika nilai *lr inc* tetap 1,05 dan nilai *lr dec* dinaikkan dari 0,6 menjadi 0,7 hasilnya nilai R² maksimum naik dari 65,1 menjadi 65,9. Nilai rata-rata R² naik dari 46 menjadi 42,1 sedangkan nilai RMSE naik dari 174 menjadi 183,78. Kemudian nilai *lr inc* dinaikkan dari 1,05 menjadi 1,2 dan nilai *lr dec* diturunkan dari 0,7 menjadi 0,6 hasilnya nilai R² maksimum naik dari 65,9 menjadi 66,5. Nilai rata-rata R² naik dari 42,1 menjadi 50,4 sedangkan nilai RMSE turun dari 183,78 menjadi 173,05. Komposisi parameter terbaik percobaan kelompok data pertama untuk *leap 1* adalah *lr inc* 1,2 dan *lr dec* 0,6.

Percobaan kelompok data kedua untuk *leap 1*. Ketika nilai *lr inc* tetap 1,05 dan nilai *lr dec* dinaikkan dari 0,6 menjadi 0,7 hasilnya nilai R² naik dari 46 menjadi 46,4. Nilai rata-rata R² naik dari 36,06 menjadi 37,8 sedangkan nilai RMSE naik dari nilai 198,13 menjadi 200,82. Kemudian nilai *lr inc* dinaikkan dari 1,05 menjadi 1,2 dan nilai *lr dec* diturunkan dari 0,7 menjadi 0,6 hasilnya nilai R² maksimum turun dari 46,4 menjadi 45,7. Nilai rata-rata R² turun dari 37,8 menjadi 37,09 sedangkan nilai RMSE turun dari 200,82 menjadi 197,55. Komposisi parameter terbaik percobaan kelompok data kedua untuk *leap 1* adalah *lr inc* 1,05 dan *lr dec* 0,7. Hasil selengkapnya disajikan pada Tabel 5.

Tabel 5. Komposisi parameter terbaik *gradient descent adaptive learning rate*

Kelompok Data	Leap 0		Leap 1		Leap 2		Leap 3	
	<i>lr in</i>	<i>lr dec</i>	<i>lr in</i>	<i>lr dec</i>	<i>lr in</i>	<i>lr dec</i>	<i>lr in</i>	<i>lr dec</i>
Pertama	1,20	0,6	1,20	0,6	1,05	0,7	1,20	0,6
Kedua	1,20	0,6	1,05	0,7	1,05	0,7	1,20	0,6

6. SIMPULAN

JST *recurrent* yang teroptimasi secara heuristik dengan menggunakan *gradient descent adaptive learning rate* dapat diterapkan dalam pendugaan curah hujan berdasarkan peubah ENSO dengan tingkat keakuratan yang cukup baik.

Hasil pendugaan curah hujan terbaik pada *leap 0* menghasilkan nilai R^2 maksimum 69,2%, *leap 1* menghasilkan nilai R^2 maksimum 66,5%, *leap 2* menghasilkan nilai R^2 maksimum 61,6%, dan *leap 3* menghasilkan nilai R^2 maksimum 55,5%.

Komposisi 75% data pelatihan & 25% data pengujian menghasilkan R^2 maksimum lebih tinggi dibandingkan komposisi 50% data pelatihan dan 50% data pengujian.

PUSTAKA

- Apriyanti, Novi. 2004. *Optimasi Jaringan Syaraf Tiruan dengan Algoritma Genetika untuk Peramalan Curah Hujan*. Bogor : Jurusan Ilmu Komputer FMIPA IPB.
- Coulibaly, Rasmussen & Bobee. 2000. *A Recurrent Neural Networks Approach Using Indices of Low Frequency Climatic Variability to Forecast Regional Annual Runoff*. Hydrol.Process. 14, 2755-2777.
- Effendy, Sobri. 2001. *Urgensi Prediksi Cuaca dan Iklim di Bursa Komoditas Unggulan Pertanian*. Bogor: Makalah Falsafah Sains Program Pasca Sarjana/S3.
- Fausett, Laurene. 1994. *Fundamentals of Neural Networks*. Prentice-Hall.
- Fitriadi. 2004. *Kombinasi Model Regresi Komponen Utama dan Arima dalam Statistical Downscaling*. Skripsi. Bogor: Jurusan Ilmu Komputer FMIPA IPB.
- Kusumadewi Sri. 2004. *Membangun Jaringan Syaraf Tiruan menggunakan Matlab & Excell Link*. Penerbit Graha Ilmu.
- Kristanto Andri. 2004. *Jaringan Syaraf Tiruan (Konsep Dasar, Algoritma dan Aplikasi)*. Penerbit Gaya Media.
- Lakshmi Sri, R.K. Tiwari & Somvanshi. 2003. *Prediction of Indian Rainfall Index (IRF) using the ENSO variability and Sunspot Cycles-An Artificial Neural Network Approach*. J.Ind.Geophys. Union vol.7, No.4.pp.173-181.
- Normakristagaluh P. 2004. *Penerapan Jaringan Syaraf Tiruan untuk Peramalan Curah Hujan*

- dalam Statistical Downscaling*. Bogor: Jurusan Ilmu Komputer FMIPA IPB.
- Walpole, E.R. 1995. *Pengantar Statistika*. Jakarta : PT Gramedia Pustaka Utama.
- Workshop JNB. 2002. *Aplikasi Jaringan Neural Buatan Pada Pattern Recognition*. Laboratorium Kecerdasan Komputasi Fakultas Ilmu Komputer Universitas Indonesia.
- Yusmen, Dedi. 1998. *Tugas Akhir: Pengaruh ENSO terhadap pola curah, hujan di Wilayah DAS Brantas Selatan-Jawa Timur*. Bandung: Jurusan Geofisika dan Meteorologi, FMIPA ITB.