

ANALISIS PERAMALAN DATA KOSONG BULANAN PASANG SURUT MENGGUNAKAN METODE *ADAPTIVE NEURO FUZZY INFERENCE SYSTEM* (ANFIS) (STUDI KASUS: STASIUN PASUT SURABAYA)

Eka Yuliandany*) L.M Sabri, Moehammad Awaluddin

Departemen Teknik Geodesi Fakultas Teknik Universitas Diponegoro
 Jl. Prof. Soedarto, SH, Tembalang, Semarang Telp.(024)76480785, 76480788
 Email: ekayuliandany@gmail.com*

ABSTRAK

Sebagai suatu fenomena yang terjadi secara periodik maka pasang surut (pasut) dapat diprediksi. Metode untuk mengkaji dan memprediksi tinggi pasut konvensional umumnya membutuhkan data dengan rentang data yang panjang. Data pasut yang lengkap dengan rentang waktu yang panjang masih sulit untuk ditemukan. Hal tersebut mendorong peneliti untuk mengaplikasikan berbagai metode untuk simulasi peramalan data kosong (*fill gap*) pada data pasut, salah satunya dengan metode ANFIS. Penelitian pasang surut ini menggunakan metode ANFIS (*Adaptive Neuro Fuzzy Inference System*) untuk melakukan peramalan data kosong (*fill gap*) pasut. Data yang digunakan adalah data pasut per jam kota Surabaya dari tahun 2000-2018. Model ANFIS untuk simulasi peramalan data kosong (*fill gap*) pada data pasut dibuat dengan panjang data pelatihan yang berbeda. Hasil dari penelitian ini diperoleh bahwa panjang data masukan tidak berpengaruh langsung terhadap kinerja ANFIS dalam melakukan peramalan data kosong (*fill gap*) pasut. Nilai RMSE *testing* terkecil terdapat pada tahun 2001 yaitu sebesar 0,000029 m dengan panjang data pelatihan per *input* sebesar 48 jam, dan nilai RMSE *testing* terbesar terdapat pada tahun 2016 yaitu sebesar 0,122940 m dengan panjang data pelatihan per *input* sebesar 360 jam. Prediksi dengan data *input* tahunan diperoleh nilai standar deviasi terkecil pada tahun 2015 sebesar 0,099 m dan nilai standar deviasi terbesar pada tahun 2007 sebesar 0,183 m dengan rata-rata nilai korelasi sebesar 0,9650. Sedangkan untuk prediksi menggunakan panjang data *input* yang berbeda diperoleh hasil prediksi dengan nilai standar deviasi terkecil terdapat pada kelompok data taun 2007-2017 sesudah dilakukan proses *fill gap* yaitu sebesar 0,106 m dan nilai standar deviasi terbesar terdapat pada kelompok data tahun 2000-2017 sebelum dilakukan proses *fill gap* sebesar 0,332 m.

Kata Kunci: ANFIS, *Fill Gap*, Pasang Surut, RMSE, Standar Deviasi

ABSTRACT

As a phenomenon that occurs periodically, the tidal can be predicted. Methods for assessing and predicting conventional tidal height generally require data with a long range data. In practice, complete tidal data with a long time span is still difficult to find. This encourages researchers to apply various methods for simulating empty data forecasting (fill gap) on tidal data, one of them is the ANFIS method. This tidal research uses the ANFIS (Adaptive Neuro Fuzzy Inference System) method to forecast the tidal fill data. The data used is the hourly tidal data of the city of Surabaya from 2000-2018. ANFIS models for the simulation of empty data forecasting (fill gap) on tidal data are made with different training data lengths. From this study, the results obtained that the length of the input data does not directly affect the performance of ANFIS in forecasting empty data (tide gap). The smallest RMSE testing value was found in 2001 which was 0.000029 m with the length of training data per input of 48 hours, and the highest RMSE value was obtained in 2016 which was 0,122940 m with the length of training data per input of 360 hours. For predictions with annual input data, the smallest standard deviation value in 2015 was 0.099 m and the largest standard deviation in 2007 was 0.183 m, with an average correlation value of 0.9650. Predictions using different input data lengths obtained prediction results with the smallest standard deviation values are found in the 2007-2017 data group after the fill gap process is equal to 0.106 m and the largest standard deviation values are found in the 2000-2017 data group before the process fill gap of 0.332 m.

Keywords: ANFIS, *Fill Gap*, Tidal, RMSE, Standard Deviation

*)Penulis Utama, Penanggung Jawab

I. Pendahuluan

I.1 Latar Belakang

Pasang surut laut adalah suatu fenomena pergerakan naik turunnya permukaan air laut secara periodik yang disebabkan oleh pengaruh gravitasi benda-benda langit terutama bulan dan matahari (Poerbandono dan Djunarsjah, 2005). Gerakan vertikal muka air laut yang periodik merupakan resultan dari gravitasi bulan dan matahari pada waktu dan kedudukan tertentu. Sebagai suatu fenomena yang terjadi secara periodik dan dapat dijelaskan secara matematis berdasarkan teori gravitasi universal dan teori gerak periodik benda-benda langit maka pasut dapat diprediksi. Berbagai metode prediksi pasut telah dikembangkan dan diaplikasikan salah satunya adalah metode harmonik.

Metode harmonik dapat dihitung dengan metode *Admiralty* maupun dengan teknik kuadrat terkecil. Ulum dan Khomsin (2014) menyebutkan bahwa metode kuadrat terkecil memberikan akurasi yang lebih baik dibandingkan dengan metode *Admiralty*.

Salah satu dari metode *soft computing* yang dapat digunakan untuk memprediksi pasut adalah dengan metode ANFIS yang mengkombinasikan antara *Artificial Neural Network* (ANN) dan *Fuzzy Inference System* (FIS). ANN melakukan perhitungan secara cepat untuk memecahkan permasalahan yang kompleks dan linier, sedangkan *fuzzy logic* atau FIS menggabungkan pengetahuan manusia dan mencari kesimpulan untuk membuat suatu keputusan atau prediksi (Pertiwi, 2017).

Metode ANFIS menggunakan jaringan syaraf tiruan yang dapat membangun model matematika dari data masukan yang digunakan sehingga dapat memodelkan prediksi variasi muka laut berdasarkan model data muka laut hasil pengukuran. Oleh karena itu, pada penelitian ini dilakukan simulasi peramalan data kosong (*fill gap*) pada data pasut menggunakan metode ANFIS. Simulasi peramalan dilakukan dengan data masukan yang bervariasi untuk memprediksi data kosong (*fill gap*) dengan interval yang berbeda. Data hasil peramalan *fill gap* digunakan sebagai data masukan untuk proses prediksi pasut. Hasil prediksi pasut akan dibandingkan dengan data pengamatan Badan Informasi Geospasial (BIG) untuk mengetahui kualitas data hasil peramalan *fill gap* dalam melakukan prediksi pasut.

I.2 Perumusan Masalah

Rumusan masalah dalam penelitian ini adalah:

1. Bagaimana pengaruh panjang data masukan terhadap kepresisian ANFIS dalam simulasi peramalan data kosong (*fill gap*) pada data pasut?
2. Bagaimana akurasi data *fill gap* ANFIS dalam melakukan prediksi data pasut?

I.3 Maksud dan Tujuan Penelitian

Penelitian ini diharapkan dapat dimanfaatkan sebagai data pendukung dalam berbagai kegiatan hidrografi, selain itu kajian tentang kinerja ANFIS dalam simulasi peramalan data kosong (*fill gap*) pada data pasut dan pengaruh panjang data masukan terhadap kinerja ANFIS diharapkan dapat menjadi informasi tentang alternatif metode untuk memprediksi pasut menggunakan data masukan yang lengkap. Tujuan penelitian ini adalah sebagai berikut:

1. Memperoleh nilai presisi peramalan data kosong (*fill gap*) berdasarkan nilai RMSE *training* dan *testing*.
2. Memperoleh nilai akurasi prediksi pasut berdasarkan hasil peramalan data kosong (*fill gap*) dengan ANFIS.

I.4 Ruang Lingkup

Ruang lingkup penelitian ini adalah:

1. Lokasi objek penelitian dilakukan pada titik pengamatan stasiun pasut di Kota Surabaya.
2. Data Penelitian yang digunakan dalam penelitian ini adalah data pasut Surabaya dari tahun 2000-2018 yang diperoleh dari hasil pengukuran stasiun pasut BIG. Data pasut yang digunakan memiliki interval perekaman tiap 1 (satu) jam.
3. Nilai presisi ANFIS diperoleh berdasarkan nilai RMSE *training* dan *testing* dengan perbandingan jumlah data *training* dan *testing* sebesar 70:30.
4. Nilai akurasi data prediksi diperoleh dari selisih antara data hasil prediksi dengan data hasil pengamatan BIG tahun 2018 dengan data *input*:
 - a. Data tahunan dari tahun 2000-2017
 - b. Data tahun 2000-2017 sebelum proses *fill gap*
 - c. Data tahun 2007-2017 sebelum proses *fill gap*
 - d. Data tahun 2007-2017 sesudah proses *fill gap*
5. Pengolahan dilakukan menggunakan *software* Matlab R2013a. Penggunaan program hanya untuk simulasi peramalan data kosong.
6. Prediksi pasut dilakukan menggunakan *software* Matlab dengan bantuan program *t-tide* v.1.3.

II. Tinjauan Pustaka

II.1 Pasang Surut (Pasut)

Poerbandono dan Djunarsjah (2005) menjelaskan pasut laut (*ocean tide*) sebagai fenomena naik dan turunnya permukaan air laut secara periodik yang disebabkan oleh pengaruh gravitasi benda-benda langit terutama bulan dan matahari. Gerakan vertikal muka air laut yang periodik merupakan resultan dari atraksi gravitasi bulan dan matahari pada waktu dan kedudukan tertentu. Gelombang pasut yang diamati di suatu lokasi merupakan superposisi dari beberapa gelombang yang masing-masing pada setiap saat

tertentu dibangkitkan oleh kedudukan benda langit tertentu.

II.1.1 Gaya Pembangkit Pasut

Gaya pembangkit pasut merupakan resultan gaya tarik bulan, matahari dan gaya sentrifugal yang mempertahankan kesetimbangan dinamik pada seluruh sistem yang ada. Gerakan dari benda angkasa tersebut akan mengakibatkan terjadinya beberapa macam gaya pada setiap titik di bumi ini, yang disebut gaya pembangkit pasang surut. Masing masing gaya akan memberikan pengaruh pada pasang surut dan disebut komponen pasang surut, dan gaya tersebut berasal dari pengaruh matahari, bulan atau kombinasi keduanya (Denafiari, 2017).

II.1.2 Konstanta Harmonik dan Tipe Pasang Surut

Perbandingan amplitudo dan fase akibat atraksi benda-benda langit tertentu pada pola pasut dinyatakan dengan konstanta-konstanta pembanding dengan simbol dan nilai tertentu untuk menjelaskan akibat atraksi gravitasi bulan atau matahari dengan kedudukan tertentu terhadap tinggi muka air. Komponen-komponen harmonik utama pasut beserta periodanya (Poerbandono dan Djunarsjah, 2005), dapat dilihat pada Tabel II.1.

Tabel II.1 Komponen harmonik pasut utama

Jenis	Nama Komponen	Perioda (Jam)	Fenomena
Semi-diurnal	M2	12.42	Gravitasi bulan dengan orbit lingkaran dan sejajar equator bumi
	S2	12.00	Gravitasi matahari dengan orbit lingkaran dan sejajar equator bumi
	N2	12.66	Perubahan jarak bulan ke bumi akibat lintasan yang berbentuk <i>elips</i>
	K2	11.97	Perubahan jarak matahari ke bumi akibat lintasan yang berbentuk <i>elips</i>
Diurnal	K1	23.93	Deklinasi sistem bulan dan matahari
	O1	25.82	Deklinasi bulan
	P1	24.07	Deklinasi matahari
Perioda panjang	Mf	327.86	Variasi setengah bulanan
	Mm	661.30	Variasi bulanan
	Ssa	2191.43	Variasi semi tahunan
Perairan dangkal	2SM2	11.61	Interaksi bulan dan matahari
	MNS2	13.13	Interaksi bulan dan matahari dengan perubahan jarak matahari akibat lintasan berbentuk <i>elips</i>
	MK3	8.18	Interaksi bulan dan matahari dengan perubahan jarak bulan akibat lintasan berbentuk <i>elips</i>
	M4	6.21	2x kecepatan sudut M2
	MS4	2.20	Interaksi M2 dan S2

Secara umum pengelompokan tipe pasut akan dijelaskan dalam Tabel II.2 berikut ini (Poerbandono dan Djunarsjah, 2005):

Tabel II.2 Pengelompokan tipe pasut

Nilai Bentuk	Jenis Pasut	Fenomena
$0 < Nf < 0.25$	Harian Ganda Murni	2x pasang sehari dengan tinggi yang relatif sama
$0.25 < Nf < 1.5$	Campuran Berganda	2x pasang sehari dengan perbedaan tinggi dan interval yang berbeda
$1.5 < Nf < 3$	Campuran Tunggal	1x atau 2x pasang sehari dengan interval yang berbeda
$Nf > 3$	Campuran Murni	1x pasang sehari, saat <i>spring</i> dapat terjadi 2x pasang

II.1.3 Prediksi Pasut

Pasut bersifat periodik sehingga dapat diramalkan. Secara matematis, proses prediksi pasut merupakan proses penambahan kurva kosinus dari komponen pasut yang didapatkan dari proses analisis harmonik pasut. Metode tradisional prediksi pasut dilakukan dengan metode analisis harmonik, yang merupakan penjumlahan dari parameter atau komponen dari pasut. Berdasarkan teori analisis harmonik, tinggi pasut dinyatakan dengan (Poerbandono dan Djunarsjah, 2005):

$$y(t) = y(o) + \sum_{i=1}^n A_i \cdot \cos(\omega_i \cdot t - \theta_i) \dots \dots \dots (1)$$

Keterangan :


- $y(t)$: tinggi muka air laut
- $y(o)$: tinggi muka air laut rata-rata
- A_i : amplitudo komponen pasut i
- ω : kecepatan sudut = $2\pi f$
- f : frekuensi
- t : waktu
- θ : keterlambatan fase

II.2 Adaptive Neuro-Fuzzy Inference System (ANFIS)

ANFIS adalah suatu metode yang menggunakan jaringan saraf tiruan (JST) untuk mengimplementasikan sistem logika samar, dimana nilai masukan diproses melalui proses JST untuk kemudian hasilnya direpresentasikan dalam nilai logika samar (*fuzzy*) (Kusumadewi, 2002 dalam Pertiwi, 2017). Salah satu keuntungan dari sistem *fuzzy* adalah kemampuannya untuk membentuk aturan dasar berdasarkan pengetahuan pengguna, yang digunakan untuk membagi kelompok *fuzzy* dan menentukan jumlah aturan *fuzzy* untuk menjelaskan hubungan dari data masukan dan keluaran.

II.2.1 Arsitektur ANFIS

Sistem *neuro-fuzzy* terdiri atas lima lapisan dengan fungsi yang berbeda untuk tiap lapisannya. Tiap lapisan terdiri atas beberapa simpul yang dilambangkan dengan kotak atau lingkaran. Lambang kotak menyatakan simpul *adaptif* artinya nilai parameternya bisa berubah dengan pembelajaran dan lambang lingkaran menyatakan simpul *nonadaptif* yang nilainya tetap seperti yang terlihat pada Gambar II.1.



Gambar II.1 Ansitektur dari ANFIS (Jang, 1997)

Penjabaran tiap lapisan dari struktur ANFIS berdasarkan Gambar II.1 adalah sebagai berikut (Jang, 1993, 1997):

1. Lapisan 1 : semua simpul pada lapisan ini adalah simpul *adaptif* (parameter dapat berubah), dimana tiap titik (*node*) pada lapisan ini beradaptasi terhadap parameter fungsi keanggotaan. Keluaran dari tiap titik adalah nilai derajat keanggotaan yang telah ditentukan oleh fungsi keanggotaan.
2. Lapisan 2 : semua simpul pada lapisan ini adalah *nonadaptif* (parameter tetap). Fungsi simpul ini adalah mengalikan setiap sinyal masukan yang datang, dimana tiap titik (*node*) pada lapisan ini merupakan titik yang tetap. Keluaran dari titik ini adalah hasil dari perkalian dari sinyal yang masuk dan yang dikirimkan ke titik selanjutnya. Tiap titik dari lapisan ini mewakili tingkat pemenuhan (*firing strength*) dari tiap aturan.
3. Lapisan 3 : setiap simpul pada lapisan ini adalah simpul *nonadaptif* yang menampilkan fungsi derajat pengaktifan ternormalisasi (*normalized firing strength*) yaitu rasio keluaran simpul ke- i pada lapisan sebelumnya terhadap seluruh keluaran lapisan sebelumnya.
4. Lapisan 4 : setiap simpul pada lapisan ini adalah simpul *adaptif*, dimana tiap titik (*node*) dari lapisan ini adalah titik yang berubah terhadap keluaran.
5. Lapisan 5 : Pada lapisan ini hanya ada satu simpul tetap, dimana tiap titik (*node*) dari lapisan ini adalah titik tetap yang menghitung keseluruhan keluaran sebagai penjumlahan dari semua sinyal yang masuk dari titik sebelumnya.

II.2.2 Proses Belajar pada ANFIS

Pembelajaran hibrid terdiri atas dua bagian yaitu arah maju (*forward pass*) dan arah mundur (*backward pass*). Pada arah maju, parameter premis dibuat tetap. Dengan menggunakan metode *Recursive Least Square Estimator* (RLSE), parameter konsekuen diperbaiki berdasarkan pasangan data masukan-keluaran. Pada arah mundur, parameter konsekuen dibuat tetap. Kesalahan yang terjadi antara keluaran jaringan *adaptif* dan keluaran sebenarnya dipropagasikan balik dengan menggunakan *gradient descent* untuk memperbaiki parameter premis. Pembelajaran ini dikenal sebagai Algoritma *Backpropagation-error* (jang, 1997). Satu tahap arah pembelajaran maju-mundur dinamakan satu *epoch*.

II.2.3 Input Space Partitioning (Pembagian Ruang Masukan)

Ada dua teknik *input space partitioning* yang digunakan dalam sistem jaringan samar, yaitu *fuzzy partitioning* dan *subtractive clustering*. Terdapat tiga metode yang termasuk dalam *fuzzy partitioning*, yaitu *grid partitioning*, *tree partitioning* dan *scatter partitioning* (Joo dan Chen, 2009 dalam Pertiwi, 2017).

II.2.4 Fungsi Keanggotaan (*Membership Function*)

Fungsi keanggotaan adalah kurva yang mendefinisikan bagaimana tiap titik dalam ruang *input* dipetakan ke dalam sebuah rentang derajat keanggotaan antara 0 dan 1 (Jang, 1997) . Fungsi keanggotaan yang umum digunakan diantaranya:

1. Fungsi keanggotaan segitiga (*triangular*)
Fungsi keanggotaan segitiga adalah fungsi keanggotaan yang paling sederhana, karena fungsi ini dibentuk menggunakan garis lurus. Kurva segitiga pada dasarnya merupakan gabungan antara dua garis linear, dan terbentuk dari tiga parameter.
2. Fungsi keanggotaan bentuk lonceng (*bell curve*).
Fungsi keanggotaan lonceng adalah bentuk kurva yang umum digunakan untuk menspesifikasikan dataset *fuzzy*. Kurva bentuk lonceng memiliki keunggulan dari kehalusan bentuknya dan kemampuannya untuk mengklasifikasikan nilai dalam data set sebagai nilai bukan nol.

II.2.5 Meningkatkan Kemampuan Generalisasi ANFIS

Pada mesin ANFIS, agar model yang telah dibuat dapat menggeneralisasi data dengan baik, pengguna perlu menghindari adanya *overfitting* dan *underfitting* dari set data *training* yang digunakan. *Overfitting* dan *underfitting* dinyatakan sebagai dua penyebab utama performa yang buruk dari mesin pembelajaran (Jang, 1997). Naba (2009), dan Paplinski (2005), menyatakan bahwa untuk mendapatkan kemampuan generalisasi dengan baik pada model ANFIS yang dibuat, penting untuk memastikan bahwa jumlah data pelatihan beberapa kali lebih besar dari jumlah parameter yang akan ditentukan.

II.2.6 Keterbatasan ANFIS

Secara khusus ANFIS hanya bekerja dengan sistem-sistem tipe Sugeno yang memiliki ciri-ciri sebagai berikut (Naba, 2009):

1. Sistem orde 0 atau 1.
2. Mempunyai *output* tunggal yang diperoleh dari *weighted average defuzzification*.
3. Semua fungsi keanggotaan *output* harus bertipe sama, dalam bentuk konstanta atau persamaan *linier*.
4. Tiap *rule* harus mempunyai fungsi keanggotaan keluaran yang berbeda dengan semua *rule* lainnya. Dengan kata lain, jumlah fungsi keanggotaan harus sama dengan jumlah *rule*.

5. Bobot tiap rule adalah 1.

Jika struktur model FIS tidak memenuhi salah satu dari sifat di atas, ANFIS tidak akan bekerja atau akan terjadi *error*. ANFIS sudah didesain *fixed*, yang mana tidak mengizinkan kita untuk mendesain sendiri fungsi keanggotaan dan fungsi defuzzifikasi.

II.3 Kontrol Kualitas Data

Kontrol kualitas data digunakan untuk verifikasi data sehingga dapat dilakukan deteksi terhadap *outlier* atau *spike*, perubahan *time series* dari data pasut, *offset*, adanya data yang kosong (*fill gap*) dan lain-lain. Kontrol kualitas data pasut dilakukan untuk data pasut per-tahun. Kontrol kualitas data dilakukan dengan menghitung standar deviasi data per tahun dengan persamaan II.2 (Widjajanti dkk., 2017)

$$\sigma = \sqrt{\frac{\sum_i^n (X_i - \bar{X})^2}{n-1}} \dots\dots\dots \text{II.2}$$

Keterangan :

- σ : Standar deviasi
- X_i : Nilai data ke-i
- \bar{X} : Nilai data prediksi ke-i
- n : Jumlah data

Sedangkan untuk rumus batas atas dan batas bawah data pasut dihitung dengan persamaan (3) dan (4):

$$\text{Batas atas} = \bar{X} + (3\sigma) \dots\dots\dots (3)$$

$$\text{Batas bawah} = \bar{X} - (3\sigma) \dots\dots\dots (4)$$

Data pasut yang dinyatakan bagus adalah data pasut yang berada di antara batas atas dan batas bawah. Apabila data pasut berada di luar batas atas dan batas bawah, maka data pasut dianggap sebagai data *outlier* dan diganti dengan “NaN”.

II.4 Root Mean Square Error (RMSE)

RMSE adalah sebuah nilai yang mengukur deviasi atau penyimpangan dari variabel acak dari sebuah nilai yang diterima. Semakin kecil nilai RMSE, maka kinerja ANFIS dinyatakan semakin baik. Nilai RMSE dapat dihitung dengan persamaan (5).

$$\text{RMSE} = \sqrt{\frac{\sum_i^n (I_u - I_p)^2}{n}} \dots\dots\dots (5)$$

Keterangan :

- I_u : Data pengukuran
- I_p : Data hasil prediksi
- n : Jumlah data

II.5 Koefisien Korelasi (R)

Koefisien korelasi (R) adalah nilai yang menunjukkan hubungan antara dua buah variabel. Uji hubungan antara data pasut pengukuran dengan data pasut hasil prediksi dilakukan dengan menghitung nilai koefisien korelasi yang dinyatakan dalam persamaan (6).

$$R = \frac{\sum_{i=1}^n (I_u - I'_u)(I_p - I'_p)}{\sqrt{\sum_{i=1}^n (I_u - I'_u)^2 \sum_{i=1}^n (I_p - I'_p)^2}} \dots\dots\dots (6)$$

Keterangan:

- I_u : Data pengukuran

- I'_u : Rata-rata data pengukuran
- I_p : Data hasil prediksi
- I'_p : Rata-rata data hasil prediksi
- n : Jumlah data

Nilai koefisien korelasi dapat dikelompokkan dalam beberapa kategori seperti yang ditampilkan pada tabel II.3.

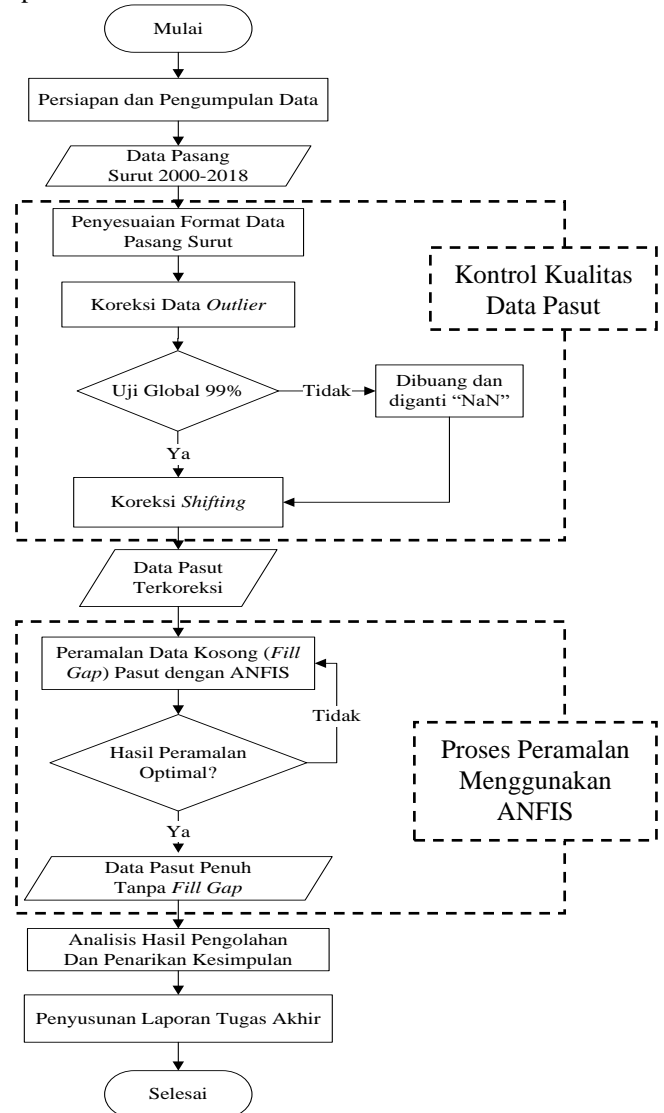
Tabel II.3 Pengelompokan koefisien korelasi

Nilai Koefisien Korelasi (R)	Keterangan
0	Tidak Ada Korelasi Antara Dua Variabel
0 < R ≤ 0,25	Korelasi Sangat Lemah
0,25 < R ≤ 0,50	Korelasi Cukup
0,50 < R ≤ 0,75	Korelasi Kuat
0,75 < R ≤ 0,99	Korelasi Sangat Kuat
1	Korelasi Sempurna

III. Data dan Metodologi

III.1 Diagram alir

Diagram alir tahapan penelitian dapat dilihat pada Gambar III.1.



Gambar III.1 Tahapan Penelitian

III.2 Tahapan Pelaksanaan

III.2.1 Persiapan dan Pengumpulan Data

Tahapan persiapan meliputi studi literatur terhadap topik bahasan, penentuan lokasi penelitian dan pengumpulan data penelitian, persiapan perangkat lunak dan perangkat keras untuk pengolahan data. Kegiatan studi literatur berupa mempelajari penelitian terdahulu, metode pengolahan data, serta literatur lain yang terkait dengan prediksi pasang surut.

III.2.2 Penyesuaian Format Data Pasang Surut

Data pasut yang diperoleh dari BIG memiliki format yang berbeda, oleh karena itu untuk mempermudah pengolahan harus dilakukan penyesuaian format data pasut. Data disesuaikan dengan format data masukan program *t_tide* (yyyy mm dd hh mm ss z) yang kemudian dikonversi kedalam format .mat.

III.2.3 Kontrol Kualitas Data Pasut

Kontrol kualitas data pasut yang dilakukan meliputi pembuangan data *outlier*, dan koreksi *shifting* untuk data pasut yang memiliki pola yang aneh.

1. Koreksi Data *Outlier*

Data pasut *outlier* adalah data pasut yang memiliki nilai perekaman di luar nilai dari sebagian besar data. Data pasut *outlier* disebabkan karena adanya lonjakan data yang bisa disebabkan karena sensor pengukur ketinggian permukaan air mengenai *noise*.

2. Koreksi *Shifting* Data Pasut

Koreksi *shifting* merupakan koreksi terhadap data pasut yang mengalami kesalahan *offset*. Kesalahan *offset* yaitu kesalahan karena referensi acuan pada saat perekaman data pasut berbeda. Koreksi *offset* dilakukan dengan menyamakan nilai referensi kelompok data yang dianggap salah terhadap kelompok data yang dianggap benar.

III.2.4 Pengisian Data Kosong (*Fill Gap*)

Konsep dari pembuatan model pengisian data kosong dengan ANFIS adalah melakukan pengisian data kosong menggunakan data pelatihan pada periode data sebelum data kosong. Apabila terdapat data kosong, x , pada jam ke i , dengan panjang data pelatihan t , maka data pelatihan model ANFIS yang dibuat adalah $x(i)$, $x(t+i)$, $x(2t+i)$, $x(3t+i)$, dan seterusnya. Proses mengisi data kosong pada data pasut dilakukan per tahun dengan metode ANFIS.

III.2.5 Prediksi Pasut Menggunakan Data *Full Hasil Fill gap*

Prediksi ini dilakukan untuk melihat bagaimana akurasi dan kualitas data hasil prediksi yang dihasilkan sesudah dilakukannya proses *fill gap*. Prediksi dilakukan untuk data pasut tahun 2018 dengan data masukan berupa data pasut tahunan dari tahun 2000 sampai 2017 yang sudah melalui proses *fill gap*.

III.2.6 Analisis Hasil Pengolahan

Analisis hasil pengolahan merupakan suatu proses yang dilakukan untuk mendapatkan suatu kesimpulan dari apa yang telah dilakukan. Berikut analisis yang dilakukan terhadap hasil pengolahan:

1. Analisis pengaruh panjang data masukan terhadap hasil *fill gap*
2. Analisis akurasi data hasil prediksi pasut sesudah dilakukan proses *fill gap*.

IV. Hasil dan Analisis

IV.1 Hasil Identifikasi Data Kosong Pasut

Identifikasi data kosong pasut dilakukan untuk mengetahui kualitas data yang akan digunakan dalam pemrosesan. Kualitas data pasut diperoleh setelah data melalui tahapan kontrol kualitas data berupa koreksi data *outlier* dan koreksi *shifting* data. Kontrol kualitas data dilakukan pertahun pada data pasut stasiun pasut Surabaya, mulai dari tahun 2000 sampai tahun 2018. Kualitas data pasut Surabaya untuk setiap tahunnya ditunjukkan pada Tabel IV.1.

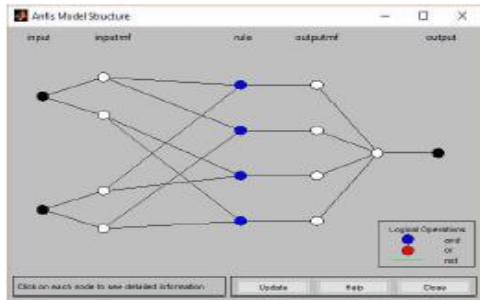
Tabel IV.1 Rincian kualitas data pasut stasiun pasut Surabaya

No	Tahun	Jumlah Data Seharusnya (Jam)	Jumlah Data yang Diterima (Jam)	Persentase	Jumlah Data Kosong (Jam)
1	2000	8784	8731	99,40%	53
2	2001	8760	7217	82,40%	1543
3	2002	8760	3443	39,30%	5317
4	2003	8760	8510	97,10%	250
5	2004	8784	8747	99,60%	37
6	2005	8760	8632	98,50%	128
7	2006	8760	7379	84,20%	1381
8	2007	8760	8667	98,90%	93
9	2008	8784	7686	87,50%	1098
10	2009	8760	8639	98,60%	121
11	2010	8760	Tidak Ada	0,00%	Tidak Ada
12	2011	8760	7979	91,10%	781
13	2012	8784	Tidak Ada	0,00%	Tidak Ada
14	2013	8760	7609	86,90%	1151
15	2014	8760	8007	91,40%	753
16	2015	8760	8738	99,70%	22
17	2016	8784	8772	99,90%	12
18	2017	8760	8631	98,50%	129
19	2018	8760	8667	98,90%	93

Tabel IV.1 menunjukkan bahwa kualitas data pasut terbaik pada stasiun pasut Surabaya adalah pada tahun 2000, 2004, 2015, dan 2016 dengan persentase data 99,4%, 99,6%, 99,7% dan 99,9%, dimana data pasut yang terekam melebihi 99% dari total keseluruhan data pasut seharusnya. Sedangkan data pasut dengan data kosong terbanyak terlihat pada tahun 2002 yaitu sebanyak 5317 jam, dan terdapat juga tahun yang tidak memiliki data perekaman pasut yaitu tahun 2010 dan 2012. Sehingga tahun 2002, 2010 dan 2012 dikatakan sebagai kelompok data yang memiliki kualitas data pasut yang jelek.

IV.2 Hasil Pembangunan Model ANFIS

Arsitektur model ANFIS yang digunakan untuk melakukan peramalan data kosong pasut dapat dilihat pada Gambar IV.1.

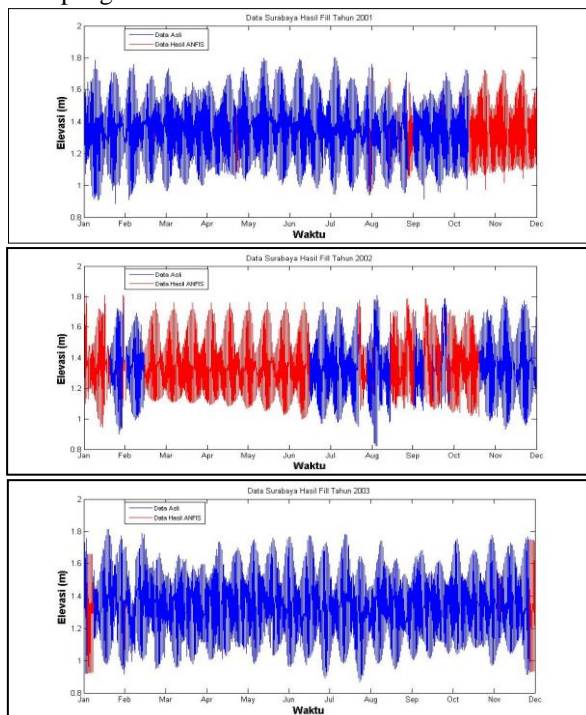


Gambar IV.1 Arsitektur model ANFIS

Gambar IV.1 menunjukkan bahwa arsitektur model ANFIS yang digunakan dalam penelitian ini dibangun dari dua data *input* yang masing-masing terdiri dari dua *membership function*, dan menghasilkan empat buah *rule* dengan *logical operations and*, yang mana dari empat *rule* tersebut akan dipetakan satu buah keluaran (*output*).

IV.3 Hasil Peramalan Fill Gap dengan ANFIS

Gambar IV.2 menunjukkan cuplikan grafik hasil peramalan data kosong (*fill gap*) menggunakan ANFIS dengan panjang data pelatihan seperti yang ditunjukkan pada Tabel III.3. Kemampuan ANFIS dalam menggeneralisasi data sangat bergantung pada pola dari data pelatihan yang digunakan. Data *input* yang digunakan pada proses pembelajaran memiliki pola yang hampir serupa dengan data *output*, sehingga data hasil peramalan memiliki pola yang sama dengan data hasil pengamatan.



Gambar IV.2 Data pasut Surabaya tahun 2001, 2002 dan 2003 yang telah melalui proses *fill gap*

IV.4 Hasil Perhitungan Konstanta Harmonik Pasut

Perhitungan konstanta harmonik dilakukan pertahun dari tahun 2000 sampai dengan tahun 2018 menggunakan program *t-tide*. Proses tersebut menghasilkan nilai konstanta harmonik pasut yang tidak jauh berbeda disetiap tahunnya. Nilai konstanta harmonik yang dihasilkan dari proses perhitungan konstanta harmonik menggunakan program *t-tide* dapat dilihat pada Tabel IV.3 sampai Tabel IV.5 berikut:

Keterangan :

■ Tertinggi ■ Terendah

Tabel IV.2 Nilai konstanta harmonik Stasiun Pasut Surabaya tahun 2000-2005


Konstanta	Tahun					
	2000	2001	2002	2003	2004	2005
*O1	0,0876	0,0826	0,0502	0,0833	0,2433	0,252
*P1	0,0443	0,0322	0,0864	0,0426	0,1256	0,14
*K1	0,1528	0,145	0,123	0,1567	0,4536	0,4363
*N2	0,0229	0,0174	0,0084	0,0192	0,0569	0,0348
*M2	0,1155	0,1108	0,0982	0,1116	0,3278	0,3562
*S2	0,0703	0,0724	0,0503	0,0706	0,1992	0,2193
*K2	0,0184	0,0193	0,0143	0,019	0,0657	0,0593
*M4	0,0068	0,0057	0,001	0,0052	0,012	0,0162
*MS4	0,0069	0,0046	0,0057	0,0075	0,0172	0,0169
F	1,2939	1,2424	1,1663	1,3172	1,3224	1,1960

Tabel IV.3 Nilai konstanta harmonik Stasiun Pasut Surabaya tahun 2006-2013

Konstanta	Tahun					
	2006	2007	2008	2009	2011	2013
*O1	0,2397	0,2018	0,2362	0,2516	0,2759	0,2282
*P1	0,1474	0,1497	0,1317	0,1356	0,1117	0,1157
*K1	0,425	0,3907	0,4575	0,4429	0,4579	0,471
*N2	0,0334	0,0501	0,041	0,0615	0,063	0,0408
*M2	0,3055	0,2833	0,2933	0,3146	0,3466	0,3234
*S2	0,1998	0,1794	0,1977	0,1955	0,2108	0,2195
*K2	0,0513	0,0374	0,0448	0,0552	0,0614	0,0386
*M4	0,0115	0,0129	0,0129	0,0182	0,018	0,0176
*MS4	0,0144	0,0149	0,019	0,0196	0,0187	0,0171
F	1,3155	1,2805	1,4128	1,3615	1,3165	1,2879

Tabel IV.4 Nilai konstanta harmonik Stasiun Pasut Surabaya tahun 2014-2018

Konstanta	Tahun				
	2014	2015	2016	2017	2018
*O1	0,2397	0,2649	0,2653	0,2567	0,2657
*P1	0,146	0,1447	0,1434	0,1278	0,1426
*K1	0,4673	0,474	0,4883	0,4305	0,4696
*N2	0,0662	0,0711	0,0741	0,0676	0,0749
*M2	0,3414	0,3816	0,3824	0,3733	0,372
*S2	0,2441	0,2237	0,2289	0,2608	0,2193
*K2	0,0763	0,062	0,065	0,0315	0,0654
*M4	0,0178	0,0166	0,0193	0,0168	0,0162
*MS4	0,0176	0,0226	0,0216	0,0204	0,0203
F	1,2075	1,2207	1,2328	1,0837	1,2435



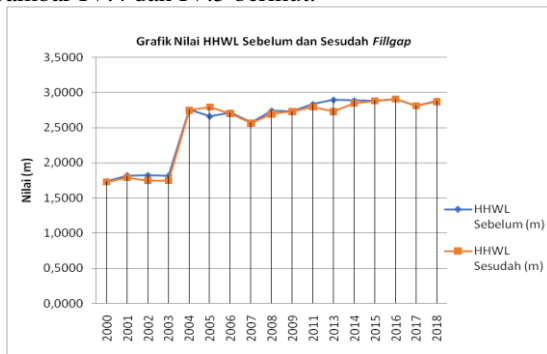
Gambar IV.3 Grafik nilai konstanta utama pasut

Tabel IV.3 – IV.5 dan Gambar IV.3 menunjukkan bahwa konstanta pasut O1 merupakan konstanta pasut yang disebabkan oleh pengaruh bulan. Konstanta pasut O1 memiliki nilai terbesar pada tahun 2011 sebesar 0,2759 m dan nilai konstanta terkecil pada tahun 2002 sebesar 0,502 m. Konstanta K1 yang merupakan konstanta pasut harian tunggal yang dipengaruhi oleh deklinasi bulan dan matahari memiliki nilai konstanta terbesar dibandingkan konstanta lainnya. Nilai konstanta K1 terbesar yaitu pada tahun 2016 sebesar 0,4883 m dan nilai konstanta terkecil pada tahun 2002 sebesar 0,1230 m.

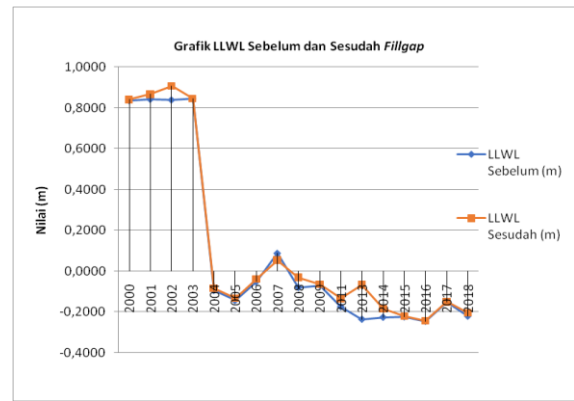
Nilai konstanta pasut M2 yang merupakan salah satu konstanta pasut ganda utama yang dipengaruhi oleh bulan memiliki nilai konstanta terbesar pada tahun 2016 yaitu sebesar 0,3824 m dan nilai konstanta terkecil pada tahun 2002 sebesar 0,0982 m. Konstanta pasut S2, konstanta ini merupakan konstanta utama dari konstanta pasut ganda yang dipengaruhi oleh matahari. Nilai konstanta S2 terbesar terlihat pada tahun 2017 yaitu sebesar 0,2608 m dan nilai konstanta terkecil pada tahun 2002 sebesar 0,0503 m.

IV.5 Hasil Perhitungan Chart Datum

Chart datum berupa *Higher High Water Large* (HHWL) dan *Lower Low Water Large* (LLWL) dihitung untuk setiap tahunnya dari tahun 2000 sampai dengan tahun 2018. Perhitungan ini dilakukan untuk mengetahui pengaruh proses *fill gap* terhadap perubahan nilai HHWL dan LLWL pada stasiun pasut Surabaya. Pola perubahan nilai HHWL, LLWL sebelum dan sesudah proses *fill gap* dapat dilihat pada Gambar IV.4 dan IV.5 berikut:



Gambar IV.4 Pola perubahan nilai HHWL sebelum dan sesudah *fill gap*



Gambar IV.5 Pola perubahan nilai LLWL sebelum dan sesudah *fill gap*

Gambar IV.4 dan IV.5 menunjukkan selisih nilai HHWL sebelum dan sesudah proses *fill gap* terbesar pada tahun 2013 sebesar 0,1689 m, dan selisih terkecil pada tahun 2017 sebesar 0,0001 m. Sedangkan untuk LLWL selisih terbesar terdapat pada tahun 2013 sebesar -0,1689 m, dan selisih terkecil pada tahun 2017 sebesar -0,0001 m.

IV.6 Analisis Pengaruh Panjang Data Pembelajaran terhadap Kepresisian ANFIS dalam Peramalan Data Kosong (*Fill Gap*)

Analisis dilakukan untuk mengetahui apakah ada pengaruh panjang data pembelajaran terhadap kinerja ANFIS dalam melakukan peramalan data kosong (*fill gap*) data pasut. Pengolahan yang dilakukan menghasilkan nilai RMSE *training* dan *testing* seperti yang terlihat pada Tabel IV.2.

Tabel IV.5 Nilai RMSE *training* dan *testing*

Tahun	Jumlah Data Kosong (jam)	Panjang Data Per input	RMSE Training (m)	RMSE Testing (m)	Kala
2000	53	24 jam	0,00009	0,00058	32
		48 jam	0,00006	0,00007	9
2001	1543	24 jam	0,00007	0,00085	30
		48 jam	0,00002	0,00003	21
2002	5317	24 jam	0,00011	0,00365	30
		48 jam	0,00003	0,00005	15
2003	250	48 jam	0,00004	0,00022	100
2004	37	24 jam	0,00006	0,00188	5
2005	128	24 jam	0,02137	0,01493	10
2006	1381	24 jam	0,00005	0,01502	5
2007	93	24 jam	0,01437	0,06325	95
2008	1098	24 jam	0,00006	0,00047	46
2009	121	24 jam	0,00004	0,00090	29
2011	781	24 jam	0,00009	0,00159	8
2013	1151	24 jam	0,00008	0,00012	65
2014	753	24 jam	0,00008	0,00034	99
2015	22	168 jam	0,06769	0,09512	29
2016	12	168 jam	0,12532	0,13434	22
		360 jam	0,12599	0,12294	66
2017	129	24 jam	0,00007	0,00044	42
2018	93	24 jam	0,00006	0,00117	54

Tabel IV.2 menunjukkan bahwa nilai RMSE dari proses pembelajaran tidak berbanding lurus dengan panjangnya data kosong (*fill gap*), dimana dalam percobaan yang dilakukan data pasut yang memiliki data kosong lebih banyak dan menggunakan data pelatihan yang pendek dalam pembelajaran mampu menghasilkan nilai RMSE yang lebih kecil dibandingkan data pasut yang memiliki data kosong lebih sedikit dan menggunakan data pelatihan yang panjang. Pola nilai RMSE tersebut, dapat dikatakan bahwa pada peramalan data kosong (*fill gap*) pasut Surabaya tahun 2000-2018, panjang data pembelajaran tidak berpengaruh langsung terhadap hasil peramalan data kosong (*fill gap*) pasut

IV.7 Analisis Akurasi Data Fill Gap ANFIS dalam melakukan Prediksi Data Pasut

1. Analisis Prediksi Pasut dengan Data Input Tahunan

Prediksi dilakukan untuk data pasut tahun 2018 dengan data masukan berupa data pasut tahunan dari tahun 2000 sampai 2017 yang sudah melalui proses *fill gap*. Prediksi pasut ini dilakukan menggunakan *software t-tide v.1.3*. Prediksi pasut yang dilakukan menunjukkan bahwa nilai elevasi pasut hasil prediksi tahun 2018 menggunakan data *input* tahun 2000-2006 menghasilkan data prediksi dengan pola pasut yang berbeda dengan nilai pasut hasil pengamatan BIG, dimana terdapat perbedaan antara fase dan amplitudonya.

Nilai elevasi pasut hasil prediksi tahun 2018 menggunakan data *input* tahun 2007-2017 menghasilkan data prediksi dengan pola pasut yang sama dengan nilai pasut hasil pengamatan BIG, dimana terdapat kesamaan pada fase namun memiliki perbedaan pada nilai amplitudonya. Setelah diketahui pola pasutnya dilakukan perhitungan standar deviasi pada masing-masing data untuk melihat seberapa besar kesalahan data pasut hasil prediksi yang dihasilkan. Hasil perhitungan standar deviasi dapat dilihat pada Tabel IV.6.

Tabel IV.6 Nilai standar deviasi data hasil prediksi

Data Input	Standar Deviasi (m)
2007	0,183
2008	0,154
2009	0,126
2011	0,115
2013	0,137
2014	0,114
2015	0,099
2016	0,128
2017	0,138

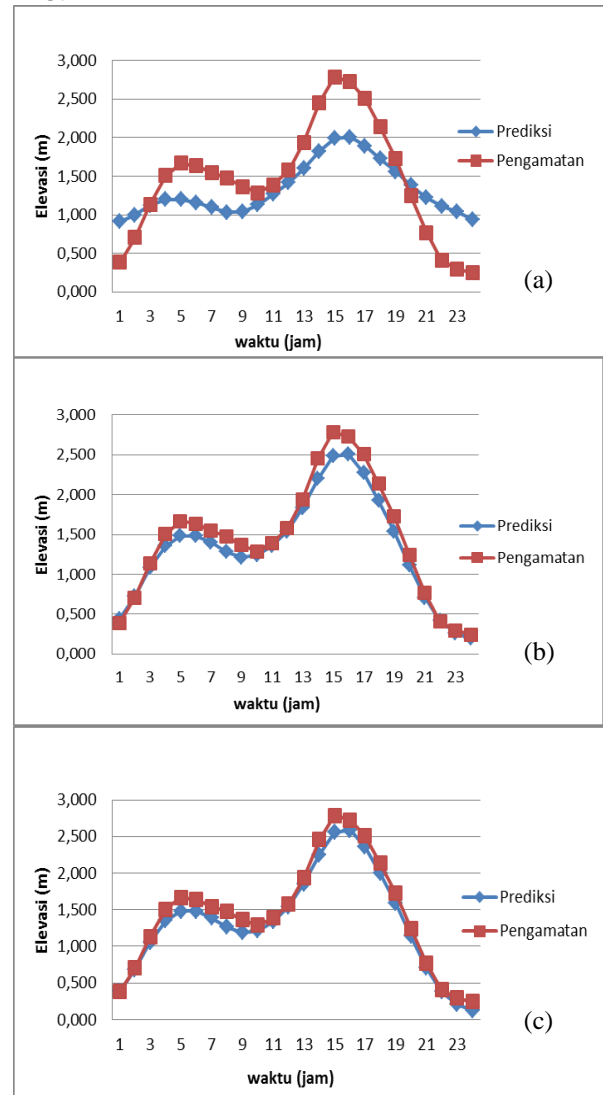
2. Analisis Prediksi Pasut dengan Panjang Data Input Berbeda

Prediksi dilakukan untuk data pasut tahun 2018 menggunakan panjang data *input* yang berbeda. Data

input yang digunakan dalam prediksi ini dibagi menjadi tiga kelompok data yaitu:

- a. Data *input* tahun 2000-2017 sebelum dilakukan proses *fill gap*
- b. Data *input* tahun 2007-2017 sebelum dilakukan proses *fill gap*
- c. Data *input* tahun 2007-2017 sesudah dilakukan proses *fill gap*

Prediksi dilakukan menggunakan *software t-tide v.1.3*. Gambar IV.6 menampilkan grafik perbandingan nilai prediksi pasut dengan nilai pasut hasil pengamatan BIG:



Gambar IV.6 Grafik *overlay* data pengamatan BIG dan data hasil prediksi dengan data *input* tahun (a) 2000-2017 sebelum *fill gap*, (b) 2007-2017 sebelum *fill gap* dan (c) 2007-2017 sesudah *fill gap*


Gambar IV.6 menunjukkan bahwa nilai elevasi pasut hasil prediksi tahun 2018 menggunakan data *input* tahun 2000-2017 sebelum dilakukan proses *fill gap* menghasilkan data prediksi dengan pola pasut yang sama dengan nilai pasut hasil pengamatan BIG, dimana terdapat kesamaan pada fase dan memiliki perbedaan yang besar terhadap nilai amplitudonya. Sedangkan untuk nilai elevasi pasut hasil prediksi tahun 2018

menggunakan data *input* tahun 2007-2017 sebelum dan sesudah dilakukan proses *fill gap* menghasilkan data prediksi dengan pola pasut yang sama dengan nilai pasut hasil pengamatan BIG, dimana terdapat kesamaan pada fase namun memiliki peredaan pada nilai amplitudonya. Setelah diketahui pola pasutnya dilakukan perhitungan standar deviasi pada masing-masing data untuk melihat seberapa besar kesalahan data pasut hasil prediksi yang dihasilkan. Hasil perhitungan standar deviasi dapat dilihat pada Tabel IV.6.

Tabel IV.7 Nilai standar deviasi

Data Input	Standar Deviasi (m)
2007-2017 Sesudah <i>Fill Gap</i>	0,106
2007-2017 Sebelum <i>Fill Gap</i>	0,110
2000-2017 Sebelum <i>Fill Gap</i>	0,332

Tabel IV.6 menunjukkan bahwa nilai standar deviasi dari masing-masing kelompok data memiliki nilai yang tidak berbeda secara signifikan, dimana nilai standar deviasi terkecil terdapat pada kelompok data tahun 2007-2017 sesudah dilakukan proses *fill gap* yaitu sebesar 0,106 m dan nilai standar deviasi terbesar terdapat pada kelompok data tahun 2000-2017 sebelum dilakukan proses *fill gap* sebesar 0,332 m. Berdasarkan nilai standar deviasi yang diperoleh dari ketiga kelompok data *input* yang digunakan dapat disimpulkan bahwa panjang data *input* yang digunakan tidak berpengaruh secara langsung dalam proses prediksi, dimana perbedaan nilai standar deviasi ini dipengaruhi oleh kualitas data masukan (*input*) yang digunakan dalam melakukan prediksi data pasut. Untuk pola perubahan nilai standar deviasinya dapat dilihat pada Gambar IV.7.



Gambar IV.7 Pola perubahan nilai standar deviasi

V. Penutup

V.1 Kesimpulan

Berikut kesimpulan yang dapat diambil dari penelitian ini:

1. ANFIS bekerja secara efektif pada data masukan dengan panjang data yang pendek. Dimana nilai RMSE *testing* terkecil terdapat pada tahun 2001 yaitu sebesar 0,000029 m dengan panjang data pelatihan per *input* sebesar 48 jam, dan nilai RMSE *testing* terbesar terdapat pada tahun 2016

yaitu sebesar 0,122940 m dengan panjang data pelatihan per *input* sebesar 360 jam.

2. Prediksi pasut yang dihasilkan setelah dilakukan proses *fill gap* pada data masukan prediksi memiliki akurasi yang tidak berbeda secara signifikan dibandingkan hasil prediksi yang dihasilkan sebelum dilakukannya proses *fill gap* pada data masukan, karena hasil prediksi ditentukan oleh kualitas data masukannya. Apabila data masukan memiliki kualitas yang baik maka akan menghasilkan data prediksi pasut yang baik.

V.2 Saran

Saran yang diberikan untuk penyempurnaan penelitian yang telah dilakukan dan untuk penelitian selanjutnya yaitu:

1. Disarankan memilih lokasi penelitian dengan kualitas data pengamatan pasut yang lebih baik.
2. Untuk penelitian selanjutnya disarankan menggunakan jenis dan jumlah fungsi keanggotaan yang lebih beragam dalam melakukan analisis.

Daftar Pustaka

Denafiar, F.S. (2017). Pembuatan Program Penentuan Konstanta Harmonik dan Prediksi Data Pasang Surut dengan Menggunakan Visual Basic For Application (Vba) Ms. Excel. Semarang : Skripsi Teknik Geodesi Universitas Diponegoro.

Jang, J.-S. (1993). ANFIS: Adaptive-Network-Based Fuzzy Inference System. IEEE Transactions on Systems, Man, and Cybernetics , 23, 665-685.

Jang, J.-S. (1997). Neuro Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence. Prentice Hall.

Naba, A. (2009). Belajar Cepat Fuzzy Logic Menggunakan Matlab. Yogyakarta: Penerbit Andi.

Paplinski, A. P. (2005). Adaptive Neuro-Fuzzy Inference System (ANFIS).

Pertiwi, M. (2017). Adaptive Neuro Fuzzy Inference System (ANFIS) untuk Prediksi Pasang Surut. Tesis. Yogyakarta: Universitas Gadjah Mada.

Poerbandono, & Djunarsjah, E. (2005). Survey Hidrografi. Bandung: Refika Aditama.

Ulum, M., & Khomsin. (2014). Perbandingan Akurasi Prediksi Pasang Surut Antara Metode Admiralty dan Metode Least Square. Skripsi. Surabaya: Jurusan Teknik Geomatika, Fakultas Teknik Sipil dan Perencanaan, Institut Teknologi Sepuluh Nopember (ITS).

Widjajanti, N dkk. (2017). Modul Kuliah Statistik dan Teori Kesalahan. Yogyakarta Geodesi, Universitas Gadjah Mada: Jurusan Teknik.