



TUGAS AKHIR - SS 141501

# PERAMALAN CURAH HUJAN UNTUK EVALUASI POLA TANAM BERDASARKAN PENANGGALAN SASIH DI BALI

I MADE ADI PURWAPUTRA  
NRP 1311 100 125

Dosen Pembimbing  
Dr. Suhartono, S.Si., M.Sc.

Program Studi S1 Statistika  
Fakultas Matematika Dan Ilmu Pengetahuan Alam  
Institut Teknologi Sepuluh Nopember  
Surabaya 2015



**TUGAS AKHIR - SS 141501**

# **PERAMALAN CURAH HUJAN UNTUK EVALUASI POLA TANAM BERDASARKAN PENANGGALAN SASIH DI BALI**

**I MADE ADI PURWAPUTRA**  
NRP 1311 100 125

Dosen Pembimbing  
Dr. Suhartono, S.Si., M.Sc.

Program Studi S1 Statistika  
Fakultas Matematika Dan Ilmu Pengetahuan Alam  
Institut Teknologi Sepuluh Nopember  
Surabaya 2015



**FINAL PROJECT - SS 141501**

# **RAINFALL FORECASTING FOR EVALUATION OF CROPPING PATTERNS BASED ON SASIH ALMANAC IN BALI**

**I MADE ADI PURWAPUTRA  
NRP 1311 100 125**

**Supervisor  
Dr. Suhartono, S.Si., M.Sc.**

**Undergraduate Programme of Statistics  
Faculty of Mathematics and Natural Sciences  
Sepuluh Nopember Institute of Technology  
Surabaya 2015**

## LEMBAR PENGESAHAN

**PERAMALAN CURAH HUJAN UNTUK EVALUASI POLA  
TANAM BERDASARKAN PENANGGALAN SASIH DI  
BALI**

### TUGAS AKHIR

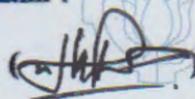
Diajukan Untuk Memenuhi Salah Satu Syarat Kelulusan  
Program Studi S-1 Jurusan Statistika  
Fakultas Matematika dan Ilmu Pengetahuan Alam  
Institut Teknologi Sepuluh Nopember

Oleh :

**I MADE ADI PURWAPUTRA**  
NRP. 1311 100 125

Disetujui oleh Pembimbing Tugas Akhir :

**Dr. Suhartono, S.Si., M.Sc.**  
NIP. 19710929 199512 1 001



Mengetahui,  
**Ketua Jurusan Statistika FMIPA-ITS**

  
**Dr. Muhammad Mashuri, M.T.**  
NIP. 19620408 198701 1 001

JURUSAN  
STATISTIKA  
SURABAYA, JULI 2015

# PERAMALAN CURAH HUJAN UNTUK EVALUASI POLA TANAM BERDASARKAN PENANGGALAN SASIH DI BALI

**Nama** : I Made Adi Purwaputra  
**NRP** : 1311100125  
**Pembimbing** : Dr. Suhartono, S.Si., M.Sc.

## ABSTRAK

*Bali dikenal sebagai daerah yang kaya akan budaya serta alamnya yang indah. Salah satu warisan dari budaya dan alam tersebut adalah sistem pertanian di Bali. Subak sebagai organisasi pertanian di Bali, serta adanya suatu penanggalan yang mengatur pola tanam menjadi kesatuan warisan yang ada di Bali. Salah satu faktor yang mempengaruhi bidang pertanian adalah alam itu sendiri, dalam hal ini berupa iklim atau cuaca. Cuaca dapat digambarkan dengan intensitas turunnya curah hujan. Permasalahannya adalah apakah penanggalan sasih masih sesuai dalam penentuan pola tanam jika dikaitkan dengan kondisi curah hujan. Tujuan dari penelitian ini adalah melihat kesesuaian penanggalan sasih yang mengatur pola pertanian di Bali, jika dikaitkan dengan kondisi curah hujan. Berdasarkan penanggalan sasih, awal musim tanam jatuh pada sasih kapitu atau sekitar bulan Januari. Setelah dilakukan evaluasi selama 25 tahun dari tahun 1990-2014, penanggalan sasih hanya kurang tepat sebanyak empat kali. Jika diproporsikan ketepatan penanggalan sasih dalam penentuan pola tanam sebesar 87,50%. Pada penelitian ini juga dilakukan peramalan curah hujan dengan tiga metode, yaitu regresi time series, ARIMA, dan recurrent neural network. Didapatkan hasil berdasarkan kriteria RMSE out sample diperoleh metode ARIMA memberikan hasil ramalan paling baik dengan nilai RMSE out sample sebesar 177,74 mm. Berdasarkan metode terbaik dilakukan peramalan 12 tahap kedepan untuk melihat evaluasi penanggalan sasih jika dikaitkan dengan prediksi curah hujan yang terjadi. Hasil yang diperoleh menunjukkan penanggalan sasih masih relevan digunakan untuk penentuan pola tanam jika dikaitkan dengan prediksi curah hujan yang terjadi.*

**Kata kunci** : curah hujan, penanggalan sasih, regresi time series, ARIMA, recurrent neural network.

“Halaman ini sengaja dikosongkan”

# RAINFALL FORECASTING FOR EVALUATION OF CROPPING PATTERNS BASED ON SASIH ALMANAC IN BALI

**Name** : I Made Adi Purwaputra  
**NRP** : 1311100125  
**Supervisor** : Dr. Suhartono, S.Si., M.Sc.

## ABSTRACT

*Bali is known as a cultural place and has a beautiful nature. One of the inheritances from its culture and nature is agriculture system in Bali. Subak as an agriculture organization in Bali, along with the almanac system that organize plant pattern are one unit as an inheritance that comes from Bali. One of factors that influence agriculture is the nature itself, in this case those are climate or weather. Weather can be described with the decrease of rainfall intensity. The issue is whether the calendar sasih still appropriate in determining the cropping pattern if it is associated with rainfall. The aim of this study is to see the suitability almanac sasih governing agricultural patterns in Bali, if it is associated with rainfall. Based on sasih almanac, the beginning of planting season is held on sasih kapitu or around January. After 25 years evaluation have been done from 1990-2014, sasih almanac have been wrong for only four times. If the accuracy of sasih almanac calculated in planting pattern related to rain outflow that have happened, it was found the accuracy is 87,50%. In this study was also conducted forecasting rainfall with three methods, namely regression time series, ARIMA, and recurrent neural network. Based on RMSE out sample's criteria have been calculated that ARIMA method gave the best result which is 177,74 mm. Based on the best method of forecasting 12 stages carried forward to see the result of sasih almanac evaluation related to rainfall predictions that have happened. The obtained result of sasih almanac is still relevant to be used in determining planting pattern if it is related to rainfall predictions that have happened.*

**Keywords:** *rainfall, sasih almanac, time series regression, ARIMA, recurrent neural network.*

“Halaman ini sengaja dikosongkan”

## KATA PENGANTAR

Puji syukur penulis panjatkan ke hadapan Ida Sang Hyang Widhi Wasa, karena atas karunia-Nya penulis dapat menyelesaikan Tugas Akhir yang berjudul “Peramalan Curah Hujan untuk Evaluasi Pola Tanam Berdasarkan Penanggalan Sasih di Bali” dengan sebaik-baiknya. Terselesaikan Tugas Akhir ini tidak lepas dari bantuan dan dukungan berbagai pihak. Oleh karena itu, penulis mengucapkan terima kasih kepada :

1. Dr. Suhartono, S.Si, M. Sc. selaku dosen pembimbing yang telah meluangkan waktu dan banyak membantu penulis dalam menyelesaikan Tugas Akhir ini.
2. Destri Susilaningrum, M.Si. dan Santi Puteri Rahayu, M.Si., Ph.D. selaku dosen penguji yang telah banyak memberikan saran sehingga Tugas Akhir dapat terselesaikan dengan baik.
3. Wibawati, M.Sc selaku dosen wali penulis yang telah banyak membantu selama perkuliahan di ITS.
4. Dr. Muhammad Mashuri, M.T. selaku Ketua Jurusan Statistika ITS.
5. Lucia Aridinanti, M.S. selaku Ketua Program Studi S1 Jurusan Statistika ITS.
6. Kedua orang tua penulis, I Nyoman Diasa dan Ni Wayan Agustini yang telah membantu penulis sampai tahap ini.
7. Kedua saudara penulis, Ni Wayan Mey Diantini dan Ni Nyoman Sintha Aprilia yang selalu mendoakan serta memotivasi penulis.
8. Keluarga kecil kontrakan dan member OO7, Gung De, Eka Yasa, Desta, Loleng, Dena, Jo, Bella, Wantek, Eronk, dll yang telah mengisi hari-hari penulis selama kuliah di Surabaya.
9. Ni Wayan Devi Aprianti yang telah memberikan penulis ide dalam pengerjaan Tugas Akhir ini.
10. Alumni IPA1 XXXII Trisma, Acong, togir, Gek Ela, Devi, Nana sahabat seperjuangan semenjak awal kuliah.

11. Keluarga besar angkatan 2011 TPKH ITS yang memberikan penulis pengalaman serta teman-teman hebat.
12. Keluarga besar TPKH ITS yang telah memberikan penulis pengalaman serta pembelajaran yang tidak terlupakan.
13. Keluarga besar SIGMA 22 yang telah banyak membantu penulis selama perkuliahan serta pengalaman dan teman-teman hebat.
14. Rekan seperjuangan Tugas Akhir Lab Bisnis dan Ekonomi yang telah bersedia berdiskusi dan berbagi literatur.
15. Made Ayu Delvina Deviany yang tidak pernah lelah memberikan semangat agar penulis cepat lulus.

Penulis berharap hasil Tugas Akhir ini dapat bermanfaat untuk berbagai pihak. Penulis menyadari bahwa dalam Tugas Akhir ini masih terdapat banyak kekurangan. Oleh karena itu penulis mengharapkan kritik dan saran dari pembaca.

Surabaya, Agustus 2015

Penulis

## DAFTAR ISI

	Halaman
Halaman Judul	
Lembar Pengesahan.....	iii
Abstrak .....	v
<i>Abstract</i> .....	vii
Kata Pengantar .....	ix
Daftar Isi.....	xi
Daftar Gambar.....	xiii
Daftar Tabel.....	xv
Daftar Lampiran .....	xvii

### **BAB I PENDAHULUAN**

1.1 Latar Belakang .....	1
1.2 Rumusan Masalah.....	4
1.3 Tujuan .....	5
1.4 Manfaat .....	5
1.5 Batasan Penelitian.....	5

### **BAB II TINJAUAN PUSTAKA**

2.1 Statistika Deskriptif.....	7
2.2 Model <i>Autoregressive Integrated Moving Average</i> (ARIMA).....	8
2.2.1 Identifikasi Model ARIMA.....	9
2.2.2 Estimasi Parameter Model ARIMA .....	11
2.2.3 Pengujian Signifikansi Parameter Model ARIMA .....	12
2.2.4 Uji Kesesuaian Model ARIMA.....	13
2.3 Regresi <i>Time Series</i> .....	14
2.3.1 Estimasi Parameter Model Regresi .....	15
2.3.2 Pengujian Signifikansi Parameter Model Regresi <i>Time Series</i> .....	16
2.3.3 Pengujian Asumsi Residual .....	17
2.4 Model <i>Recurrent Neural Network</i> (RNN).....	18
2.5 Kriteria Pemilihan Model Terbaik.....	21
2.6 Uji Nonlinieritas.....	21

	Halaman
2.7 Penanggalan <i>Sasih</i> Bali (Tahun <i>Saka</i> ).....	22
2.8 Pola Tanam.....	25
2.9 Curah Hujan .....	25
<b>BAB III METODOLOGI PENELITIAN</b>	
3.1 Sumber Data dan Variabel Penelitian .....	27
3.2 Langkah Analisis.....	28
3.3 Diagram Alir.....	30
<b>BAB IV ANALISIS DAN PEMBAHASAN</b>	
4.1 Karakteristik Kondisi Curah Hujan dari Tahun 1990- 2014 di Desa Jatiluwih .....	37
4.2 Penyesuaian Pola Pertanian Berdasarkan Penanggalan <i>Sasih</i> dengan Kondisi Curah Hujan yang Terjadi .....	39
4.3 Peramalan Curah Hujan.....	43
4.3.1 Model Regresi <i>Time Series</i> .....	44
4.3.2 Model ARIMA.....	51
4.3.3 Model RNN.....	55
4.3.3.1 Model RNN Berdasarkan Model Regresi <i>Time Series</i> Terbaik.....	55
4.3.3.2 Model RNN Berdasarkan Model ARIMA Terbaik .....	57
4.4 Perbandingan Model Regresi <i>Time Series</i> , ARIMA, dan RNN .....	58
4.5 Penyesuaian Pola Pertanian Berdasarkan Penanggalan <i>Sasih</i> dengan Prediksi Curah Hujan yang Terjadi .....	62
<b>BAB V KESIMPULAN DAN SARAN</b>	
5.1 Kesimpulan .....	65
5.2 Saran .....	65
<b>DAFTAR PUSTAKA</b> .....	67
<b>LAMPIRAN</b> .....	71

## DAFTAR TABEL

	Halaman
<b>Tabel 2.1</b> Struktur Plot ACF dan PACF pada Model ARIMA	10
<b>Tabel 2.2</b> ANOVA.....	16
<b>Tabel 2.3</b> Pola Tanam Pertanian Berdasarkan Penanggalan <i>Sasih</i> .....	24
<b>Tabel 4.1</b> Karakteristik Data Curah Hujan .....	38
<b>Tabel 4.2</b> Kategori Curah Hujan Berdasarkan BMKG.....	39
<b>Tabel 4.3</b> Kondisi Curah Hujan di Desa Jatiluwih Tahun 1990-2014.....	40
<b>Tabel 4.4</b> Estimasi Parameter Regresi <i>Time Series</i> .....	44
<b>Tabel 4.5</b> Uji Asumsi <i>White Noise</i> Model Regresi <i>Time Series</i> .....	45
<b>Tabel 4.6</b> Data Pengamatan <i>Outlier</i> .....	47
<b>Tabel 4.7</b> Estimasi Parameter Persamaan (4.3) .....	48
<b>Tabel 4.8</b> Nilai <i>Skewness</i> dan <i>Kurtosis</i> Model Regresi <i>Time Series</i> .....	50
<b>Tabel 4.9</b> Model ARIMA Intensitas Curah Hujan.....	53
<b>Tabel 4.10</b> Nilai RMSE Model ARIMA.....	54
<b>Tabel 4.11</b> Uji Nonlinieritas Terasvirta .....	55
<b>Tabel 4.12</b> RMSE Model RNN input Regresi <i>Time Series</i> .....	56
<b>Tabel 4.13</b> RMSE Model RNN input ARIMA .....	57
<b>Tabel 4.14</b> RMSE Model Regresi <i>Time Series</i> , ARIMA, dan RNN .....	59
<b>Tabel 4.15</b> Ramalan Curah Hujan dengan Metode ARIMA.....	62
<b>Tabel 4.16</b> Kategori Curah Hujan Berdasarkan Hasil Ramalan ARIMA.....	62

“Halaman ini sengaja dikosongkan”

## DAFTAR GAMBAR

	Halaman
<b>Gambar 2.1</b> Fungsi <i>Tangent Sigmoid</i> .....	18
<b>Gambar 2.2</b> Struktur Model Jordan-RNN (2,3,1).....	18
<b>Gambar 2.3</b> Penanggalan Bali untuk Bidang Pertanian .....	23
<b>Gambar 3.1</b> Langkah Analisis .....	31
<b>Gambar 3.2</b> Langkah Analisis Metode Regresi <i>Time Series</i> ....	33
<b>Gambar 3.3</b> Langkah Analisis Metode ARIMA.....	34
<b>Gambar 3.4</b> Langkah Analisis Metode RNN .....	35
<b>Gambar 4.1</b> Plot <i>Time Series</i> Kondisi Curah Hujan di Desa Jatiluwih Tahun 1990-2014.....	37
<b>Gambar 4.2</b> <i>Individual Plot</i> Kondisi Curah Hujan Tiap Bulannya.....	38
<b>Gambar 4.3</b> Persentase Keberhasilan Penanggalan <i>Sasih</i> .....	41
<b>Gambar 4.4</b> Rata-Rata Produktivitas Hasil Panen.....	42
<b>Gambar 4.5</b> Rata-Rata Produktivitas Hasil Panen Berdasar- kan Kondisi Curah Hujan .....	43
<b>Gambar 4.6</b> Plot ACF Residual Model Regresi .....	45
<b>Gambar 4.7</b> Plot ACF Residual Persamaan (4.2).....	46
<b>Gambar 4.8</b> Plot ACF Residual Persamaan (4.4).....	50
<b>Gambar 4.9</b> Distribusi Residual Persamaan (4.4) .....	51
<b>Gambar 4.10</b> Uji <i>Stasioner</i> Data dalam Varians .....	52
<b>Gambar 4.11</b> Plot (a) ACF dan Plot (b) PACF.....	52
<b>Gambar 4.12</b> Plot (a) ACF dan Plot (b) PACF Data Hasil <i>Differencing</i> 12.....	53
<b>Gambar 4.13</b> <i>Scatterplot Z</i> dengan (a) $Z_{t-1}$ , (b) $Z_{t-2}$ , (c) $Z_{t-4}$ , dan (d) $Z_{t-12}$ untuk Model Regresi <i>Time Series</i> .....	60
<b>Gambar 4.14</b> <i>Scatterplot Z</i> dengan (a) $Z_{t-1}$ , (b) $Z_{t-12}$ , dan (c) $Z_{t-13}$ , untuk Model ARIMA.....	60
<b>Gambar 4.15</b> Ramalan <i>In Sample</i> Metode ARIMA .....	61
<b>Gambar 4.16</b> Ramalan <i>Out Sample</i> Metode ARIMA.....	61

“Halaman ini sengaja dikosongkan”

## DAFTAR LAMPIRAN

	Halaman
<b>Lampiran A</b> Data Curah Hujan di DesaJatiluwih.....	71
A1. Data In Sample.....	71
A2. Data Out Sample.....	71
<b>Lampiran B</b> Program SAS untuk Pemodelan ARIMA .....	72
<b>Lampiran C</b> Program MATLAB untuk Pemodelan RNN.....	73
C1. Pemodelan Jordan –RNN (14,1,1) untuk data intensitas curah hujan input Regresi Time Series.....	73
C2. Pemodelan Jordan –RNN (14,1,1) untuk data intensitas curah hujan input ARIMA ....	75
<b>Lampiran D</b> Model Regresi Time Series.....	77
D1. Estimasi model regresi <i>time series</i> .....	77
D2. <i>Lagrange multiplier test</i> .....	78
<b>Lampiran E</b> Model ARIMA.....	79
<b>Lampiran F</b> Model RNN.....	80
F1. Model RNN input Regresi Time Series.....	80
F2. Model RNN input ARIMA.....	81
<b>Lampiran G</b> Contoh Perhitungan Manual Uji Terasvirta dengan Satu Variabel Prediktor .....	82

“Halaman ini sengaja dikosongkan”

# BAB I

## PENDAHULUAN

### 1.1 Latar Belakang

Sebagai bagian dari gugusan kepulauan Nusantara, Pulau Bali termasuk salah satu dari provinsi Republik Indonesia. Sebuah Negara dengan luas daratan mencapai 2.000.000 km<sup>2</sup> dengan rangkaian pulau-pulaunya yang membentang sejauh 5.000 km dari Sumatera hingga Papua, ditambah dengan luas perairannya yang mencapai 5.000.000 km<sup>2</sup>. Terletak diantara Jawa dan Lombok, tepatnya pada 8° garis lintang selatan, pulau Bali yang berukuran hanya 0,3% dari seluruh luas daratan RI, hampir tidak terlihat dalam peta Nusantara. Namun tidak disangkal lagi namanya jauh lebih terkenal dibandingkan Indonesia. Kekhasan ini disebabkan reputasi pulau Bali sebagai surga pariwisata. Anggapan tersebut dibangun atas wacana orientalis yang ingin melihat Bali sebagai museum hidup yang berlandaskan budaya (Picard, 1992).

Salah satu warisan dari budaya Pulau Bali adalah sebuah sistem penanggalan tradisional. Penanggalan Bali atau Kalendar Saka Bali sangat penting dalam kehidupan sosial budaya masyarakat Bali. Beberapa hari suci seperti Hari Raya Nyepi dan Siwaratri ditetapkan berdasarkan Kalender Saka, begitu pula dengan Piodalan Pura di Bali (Destra, 2013). Selain itu, penanggalan Bali juga dijadikan acuan dalam memulai kegiatan-kegiatan tertentu seperti bidang pertanian yang dijadikan acuan dalam pola tanam (Kec. Penebel, 2013). Selain penanggalan Bali, salah satu warisan budaya yang erat kaitannya dengan bidang pertanian di Bali adalah *subak*. *Subak* sendiri merupakan suatu sistem irigasi di Bali yang sudah ada sejak ratusan tahun yang lalu, namun demikian belum diketahui dengan pasti tentang kapan dan bagaimana *subak* pertama kali dibentuk (Pitana, 1993). Dengan berjalannya waktu *subak* sendiri berkembang menjadi sebuah organisasi yang menyatakan bahwa *subak* merupakan masyarakat hukum adat yang bersifat sosio-agraris-religius, yang

terdiri atas petani yang menggarap sawah pada suatu areal persawahan yang mendapatkan air dari suatu sumber (Geertz, 1980). Melihat hal tersebut, pertanian di Bali sangat erat kaitannya dengan warisan budaya yang ada. Namun pada akhirnya sistem-sistem yang telah diatur dalam budaya tersebut tidak dapat mengantisipasi faktor alam pada bidang pertanian.

Salah satu faktor alam yang dapat mempengaruhi pertumbuhan output pertanian adalah iklim. Akan tetapi, adanya perubahan pola hujan pada tahun 1990-2000 dan intensitas hujan berubah makin tinggi mengakibatkan pergeseran awal musim dan pola tanam petani (Ratag, 2007). Salah satu unsur iklim yang paling banyak digunakan dalam penelitian adalah curah hujan yang erat kaitannya dengan penentuan kalender masa tanam. Sehingga dengan dilakukannya peramalan kondisi curah hujan akan sangat bermanfaat bagi sektor pertanian dalam penentuan kalender tanam.

Saat ini BMKG sebagai institusi yang menaungi masalah iklim seringkali menggunakan metode-metode tertentu dalam meramalkan curah hujan. Salah satu metode yang paling umum digunakan dalam peramalan adalah metode ARIMA. Metode ARIMA mampu memberikan hasil yang baik, namun harus memenuhi beberapa asumsi, diantaranya adalah white noise, berdistribusi normal, stasioner dalam mean dan varians (Wei, 2006). Selain itu metode ARIMA belum mampu mengakomodasi adanya data ekstrim yang dimana biasanya data curah hujan bersifat musiman. Selain metode ARIMA, beberapa penelitian peramalan curah hujan juga menggunakan metode Kalman Filter yang dilakukan oleh Mirawati (2013) tentang peramalan curah hujan di Kota Semarang. Penelitian peramalan curah hujan juga dilakukan oleh Widosari (2011) dengan metode Wavalet untuk memprediksi curah hujan di Kota Samarinda. Pada dasarnya cukup banyak metode peramalan yang dapat diaplikasikan dalam peramalan curah hujan dan sudah banyak pula yang diaplikasikan seperti metode VAR-NN dan GSTAR-NN oleh Diani (2013) untuk peramalan curah hujan di Kabupaten Malang. Metode

GRNN oleh Warsito, Tarno, dan Sugiharto (2008) untuk peramalan curah hujan guna perencanaan pola tanam di Jawa Tengah. Jika kondisi curah hujan dikaitkan kembali dengan pola pertanian di Bali yang berdasarkan penanggalan Bali, tentu akan menimbulkan pertanyaan apakah penanggalan Bali tersebut masih efektif digunakan.

Untuk melihat masih sesuai atau tidaknya fungsi penanggalan Bali untuk pola tanam pertanian jika dikaitkan dengan curah hujan yang terjadi, tentu dapat dilihat kesesuaian kondisi curah hujan dengan pola tanam yang ada. Kesesuaian kondisi yang dilihat adalah kondisi curah hujan berdasarkan tahapan-tahapan masa tanam dengan kondisi curah hujan yang terjadi berdasarkan penanggalan Bali. Jika masih ada kesesuaian maka penanggalan Bali masih efektif digunakan. Selain melihat kondisi yang terjadi selama ini, tentu akan sangat menarik jika melihat kondisi yang akan datang. Sehingga metode peramalan dapat digunakan untuk memprediksi kondisi curah hujan kedepannya, yang selanjutnya akan dilihat kesesuaian kondisinya dengan kondisi curah hujan berdasarkan tahapan-tahapan masa tanam.

Dalam penelitian ini tidak semua daerah di Bali bisa dijadikan objek penelitian. Hal tersebut dikarenakan jenis tanaman padi yang ditanam berbeda-beda. Pola tanam berdasarkan penanggalan sasih hanya bisa diterapkan untuk jenis padi beras merah atau lebih dikenal padi Bali, dimana pola pertaniannya hanya satu kali panen dalam setahun. Oleh karena itu daerah yang akan dijadikan objek penelitian adalah daerah yang masih menggunakan sistem penanggalan Bali dan jenis padi Bali. Menurut informasi dari Kecamatan Penebel (2013) salah satu daerah yang masih menggunakan sistem tersebut adalah daerah pertanian di Jatiluwih, Kabupaten Tabanan. Sehingga pengambilan data curah hujan yang akan digunakan berdasarkan stasiun pengamatan disekitar daerah Jatiluwih. Adapun data curah hujan yang akan digunakan dari tahun 1990 sampai tahun 2014 untuk melihat pergeseran musim yang terjadi.

Dalam penelitian ini akan digunakan beberapa metode untuk mendapatkan model ramalan yang terbaik. Adapun metode peramalan yang akan digunakan adalah metode *Seasonal Autoregressive Integrated Moving Average* (SARIMA), *Time Series Regression*, dan *Recurrent Neural Network* (RNN). Metode tersebut dipilih karena mampu mengakomodasi nilai ekstrim dalam hal ini curah hujan yang biasanya bersifat musiman, serta ketersediaan data curah hujan dalam bentuk bulanan. Peramalan dengan metode SARIMA pernah dilakukan oleh Huda, Choiruddin, dan Budiarto (2012) untuk peramalan curah hujan di Kabupaten Mojokerto guna penyusunan pola tanam. Selanjutnya untuk metode *Time Series Regression* pernah dilakukan oleh Perdana (2010) untuk peramalan data penjualan pakaian di Boyolali. Sedangkan untuk metode RNN sendiri pernah dilakukan untuk peramalan konsumsi listrik jangka pendek di Gresik oleh Suhartono dan Endharta (2009). Dari ketiga metode tersebut akan dipilih model terbaik berdasarkan kriteria kebaikan model. Dalam penelitian ini kriteria kebaikan model yang akan digunakan sebagai pembanding adalah nilai RMSE.

## **1.2 Rumusan Masalah**

Untuk melihat masih sesuai atau tidaknya fungsi penanggalan Bali untuk pola tanam pertanian jika dikaitkan dengan curah hujan yang terjadi, tentu dapat dilihat kesesuaian kondisi curah hujan dengan pola tanam yang ada. Kesesuaian kondisi yang dilihat adalah kondisi curah hujan berdasarkan tahapan-tahapan masa tanam dengan kondisi curah hujan yang terjadi berdasarkan penanggalan Bali. Jika masih ada kesesuaian maka penanggalan Bali masih efektif digunakan. Selain melihat kondisi yang terjadi selama ini, tentu akan sangat menarik jika melihat kondisi yang akan datang. Sehingga metode peramalan dapat digunakan untuk memprediksi kondisi curah hujan kedepannya, yang selanjutnya akan dilihat kesesuaian kondisinya dengan kondisi curah hujan berdasarkan tahapan-tahapan masa

tanam. Berdasarkan pada uraian tersebut, maka terdapat empat rumusan masalah yang akan dibahas.

1. Bagaimana karakteristik keadaan curah hujan yang terjadi selama waktu pengamatan di daerah penelitian?
2. Bagaimana kesesuaian penggunaan penanggalan Bali pada pola tanam pertanian di Bali jika dikaitkan dengan kondisi curah hujan yang terjadi?
3. Bagaimana model ramalan curah hujan terbaik menggunakan metode *Time Series Regression*, SARIMA, dan RNN?
4. Bagaimana kesesuaian penggunaan penanggalan Bali kedepannya pada pola tanam pertanian di Bali jika dikaitkan dengan prediksi kondisi curah hujan yang terjadi?

### **1.3 Tujuan**

Berdasarkan rumusan masalah, maka ada empat tujuan penelitian yang akan dicapai.

1. Melihat karakteristik keadaan curah hujan yang terjadi selama waktu pengamatan di daerah penelitian.
2. Mengetahui kesesuaian penggunaan penanggalan Bali pada pola tanam pertanian di Bali jika dikaitkan dengan kondisi curah hujan yang terjadi.
3. Mengetahui model ramalan curah hujan terbaik menggunakan metode *Time Series Regression*, SARIMA, dan RNN.
4. Mengetahui kesesuaian penggunaan penanggalan Bali kedepannya pada pola tanam pertanian di Bali jika dikaitkan dengan prediksi kondisi curah hujan yang terjadi.

### **1.4 Manfaat**

Manfaat dari penelitian ini adalah hasil penelitian dapat menjadi informasi yang berguna bagi instansi yang terkait seperti *Subak* yang merupakan organisasi pertanian di Bali. Diharapkan hasil dari penelitian ini dapat menjadi pertimbangan dalam penggunaan penanggalan Bali khususnya untuk bidang pertanian.

### **1.5 Batasan Penelitian**

Dalam penelitian ini, pola pertanian yang diteliti hanya pola pertanian tanaman padi. Hal tersebut dikarenakan pada

penanggalan Bali hanya menyebutkan acuan untuk pertanian tanaman padi. Selain itu pada penelitian ini hanya melihat pengaruh pola tanam berdasarkan kondisi curah hujan dimana banyak penelitian yang mengaitkannya dengan pertanian tanaman padi.

## BAB II TINJAUAN PUSTAKA

Pada bab ini dijelaskan tentang teori dan konsep dalam pembentukan model regresi *time series*, ARIMA, dan RNN, serta pengertian tentang penanggalan *sasih* dibidang pertanian.

### 2.1 Statistika Deskriptif

Statistika deskriptif adalah suatu metode yang berkaitan dengan pengumpulan dan penyajian suatu data sehingga memberikan informasi yang berguna (Walpole, 2010). Jenis-jenis penyajian dalam statistika deskriptif yaitu ukuran pemusatan data (*mean*, median, modus), penyebaran data (*varians*, standar deviasi, *range*), penyusunan tabel, diagram batang, dan grafik. Statistika deskriptif hanya terbatas memberikan gambaran luar dari suatu gugus data dan tidak mengambil suatu keputusan. Adapun rumus untuk perhitungan salah satu ukuran pemusatan data yaitu *mean* adalah sebagai berikut

$$\bar{Z} = \frac{1}{n} \sum_{t=1}^n Z_t, \quad (2.1)$$

sedangkan salah satu ukuran penyebaran data yaitu standar deviasi dapat dihitung dengan rumus sebagai berikut

$$s = \sqrt{\frac{\sum_{t=1}^n (Z_t - \bar{Z})^2}{n-1}}. \quad (2.2)$$

Nilai dari *mean* dan standar deviasi tersebut dapat menggambarkan secara umum karakteristik data. Selain nilai-nilai tersebut, statistika deskriptif juga mencakup diagram ataupun grafik. Salah satunya adalah *skewness* dan *kurtosis* dimana *skewness* adalah derajat kemiringan suatu distribusi data sedangkan *kurtosis* adalah derajat keruncingan suatu data. Adapun fungsi dari nilai *skewness* dan *kurtosis* adalah untuk menguji secara eksploratif (deskriptif) apakah pendekatan bentuk kurva suatu distribusi data memiliki distribusi normal. Nilai

*skewness* ( $Sk$ ) dan *kurtosis* ( $Kc$ ) dapat dihitung dengan rumus sebagai berikut

$$Sk = \frac{n}{(n-1)(n-2)} \sum_{i=1}^n \left( \frac{Z_i - \bar{Z}}{s} \right)^3 \quad (2.3)$$

$$Kc = \left\{ \frac{n(n+1)}{(n-1)(n-2)(n-3)} \sum_{i=1}^n \left( \frac{Z_i - \bar{Z}}{s} \right)^4 \right\} - \frac{3(n-1)^2}{(n-2)(n-3)} \quad (2.4)$$

dimana distribusi normal memiliki nilai *skewness* dan *kurtosis* bernilai 0.

## 2.2 Model Autoregressive Integrated Moving Average (ARIMA)

Model *Autoregressive Integrated Moving Average* (ARIMA) merupakan model yang dapat mengimplementasikan suatu proses *time series* yang bersifat tidak stasioner secara univariat (Wei, 2006). Secara umum model ARIMA dituliskan dengan notasi ARIMA ( $p, d, q$ ) sebagai berikut

$$\phi_p(B)(1-B)^d Z_t = \theta_0 + \theta_q(B)e_t, \quad (2.5)$$

apabila model ARIMA mempunyai pola musiman (*seasonal*), model yang dibentuk secara umum sebagai berikut

$$\phi_p(B)\Phi_P(B^S)(1-B)^d(1-B^S)^D Z_t = \theta_q(B)\Theta_Q(B^S)e_t, \quad (2.6)$$

dengan :

$$\phi_p(B) : (1 - \phi_1 B - \dots - \phi_p B^p),$$

$$\Phi_P(B^S) : (1 - \Phi_1 B^S - \dots - \Phi_P B^{PS}),$$

$$\theta_q(B) : (1 - \theta_1 B - \dots - \theta_q B^q),$$

$$\Theta_Q(B^S) : (1 - \Theta_1 B^S - \dots - \Theta_Q B^{QS}),$$

$B$  : operator *backshift*,

$p$  dan  $P$  : orde *Autoregressive* (AR) non-musiman dan musiman,

$q$  dan  $Q$  : orde *Moving Average* (MA) non-musiman dan musiman,

$d$  dan  $D$  : orde *differencing* non-musiman dan musiman,

$S$  : orde *seasonal/musiman*.

### 2.2.1 Identifikasi Model ARIMA

Dalam analisis *time series*, tahap yang paling krusial yaitu mengidentifikasi dan membuat model yang sesuai dengan pola data. Menurut Wei (2006), untuk mengidentifikasi model menggunakan 4 tahapan.

1. Membuat Plot *Time Series* dan Memilih Transformasi yang Tepat

Tahap pertama yang dilakukan yaitu membuat plot pada data. Dalam pemeriksaan plot harus memperhatikan apakah data dipengaruhi oleh *trend*, musiman (*seasonal*), *outlier*, dan semua fenomena tidak normal dan tidak stasioner. Maka dari itu diperlukan transformasi untuk stasioner dalam *varians* dan *differencing* untuk stasioner dalam *mean*.

2. Menghitung dan Memeriksa ACF dan PACF pada Data Asli

Pemeriksaan ini berfungsi untuk konfirmasi lanjutan dalam keperluan orde *differencing*, sehingga data yang telah *didifferencing* sudah stasioner.

a. *Autocorrelation Function* (ACF)

ACF merupakan suatu koefisien yang menunjukkan hubungan linier pada data *time series* antara  $Z_t$  dengan  $Z_{t+k}$ . Suatu proses *time series* dikatakan stasioner apabila nilai dari  $E(Z_t) = \mu$  dan nilai dari  $\text{var}(Z_t) = E(Z_t - \mu)^2 = \sigma^2$ , dengan masing-masing nilai rata-rata dan *varians* konstan. Untuk menghitung nilai autokovarians antara  $\{Z_t\}$  dengan  $\{Z_{t+k}\}$  sebagai berikut

$$\gamma_k = \text{cov}(Z_t, Z_{t+k}) = E(Z_t - \mu)(Z_{t+k} - \mu) \quad (2.7)$$

dimana  $(\gamma_k)$  adalah fungsi autokovarians dengan  $k=0,1,2,\dots$ . Sedangkan untuk fungsi autokorelasi dalam sampel antara  $\{Z_t\}$  dengan  $\{Z_{t+k}\}$ , dimana  $k=0,1,2,\dots$  dapat ditulis dengan persamaan sebagai berikut.

$$\hat{\rho}_k = \frac{\sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^n (Z_t - \bar{Z})^2} = \frac{\hat{\gamma}_k}{\hat{\gamma}_0} \quad (2.8)$$

b. Partial Autocorrelation Function (PACF)

PACF berfungsi untuk mengukur tingkat keeratan hubungan pada data *time series* antara  $Z_t$  dengan  $Z_{t+k}$  setelah pengaruh  $Z_{t+1}, Z_{t+2}, \dots, Z_{t+k-1}$  dikeluarkan. Perhitungan nilai PACF lag ke- $k$  dimulai dari menghitung  $\hat{\phi}_{11} = \hat{\rho}_1$ , sedangkan fungsi auto korelasi parsial antara  $\{Z_t\}$  dengan  $\{Z_{t+k}\}$  dapat dituliskan sebagai berikut (Wei, 2006)

$$\phi_{kk} = \text{corr}(Z_t, Z_{t+k} | Z_{t+1}, \dots, Z_{t+k-1})$$

$$\hat{\phi}_{k+1, k+1} = \frac{\hat{\rho}_{k+1} - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_{k+1-j}}{1 - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_j} \quad (2.9)$$

dengan ,

$$\hat{\phi}_{k+1, j} = \hat{\phi}_{kj} - \hat{\phi}_{k+1, k+1} \hat{\phi}_{k, k+1-j} \quad j=1, 2, \dots, k.$$

3. Menghitung dan Memeriksa ACF dan PACF pada Data Stasioner

Pemeriksaan ini berfungsi untuk mengidentifikasi orde dari  $p$  dan  $q$ . Tujuan identifikasi ini adalah untuk penentuan model ARIMA sementara sebelum diuji apakah sudah memenuhi asumsi yang ada. Untuk menentukan orde  $p$  dapat dilihat melalui plot PACF dan untuk menentukan orde  $q$  dilihat melalui plot ACF yang ditunjukkan pada Tabel 2.1 berikut.

**Tabel 2.1** Struktur Plot ACF dan PACF pada Model ARIMA

Model	ACF	PACF
AR ( $p$ )	<i>Dies down</i>	<i>Cut off after lag-<math>p</math></i>
MA ( $q$ )	<i>Cut off after lag-<math>q</math></i>	<i>Dies down</i>
ARMA ( $p, q$ )	<i>Dies down</i>	<i>Dies down</i>
AR ( $p$ ) atau MA( $q$ )	<i>Cut off after lag-<math>q</math></i>	<i>Cut off after lag-<math>p</math></i>
Tidak ada order AR atau MA ( <i>white noise</i> )	<i>No spike</i>	<i>No spike</i>

#### 4. Menguji *Deterministic Trend Term* pada $\theta_0$

Pengujian ini dilakukan apabila model mempunyai orde *differencing* ( $d > 0$ ). Pada persamaan (2.5) parameter  $\theta_0$  biasanya dihilangkan sehingga mampu mewakili data dengan perubahan acak pada level, *slope*, maupun *trend*. Namun, jika mempunyai alasan yang kuat bahwa data yang telah *differencing* masih mengandung *trend*, maka dapat melakukan pengujian.

### 2.2.2 Estimasi Parameter Model ARIMA

Setelah melakukan identifikasi model ARIMA secara sementara (*tentative*), kemudian dilanjutkan dengan estimasi parameter yang digunakan dalam model ARIMA. Secara umum estimasi parameter dapat dilakukan menggunakan beberapa cara atau metode seperti metode *least square*, *moment*, *maximum likelihood*, dan *unconditional least square* (Cryer & Chan, 2008). Dalam pemodelan linier, metode *least square* merupakan metode yang paling sering digunakan dalam estimasi parameter. Untuk contoh penerapan metode *least square* dapat dilihat pada model AR (1) sebagai berikut

$$Z_t - \mu = \phi(Z_{t-1} - \mu) + e_t, \quad (2.10)$$

dengan  $Z_t$  sebagai variabel dependen dan  $Z_{t-1}$  sebagai variabel independen. Estimasi dengan metode *least square* didapatkan melalui meminimumkan jumlah kuadrat *error*, dengan *error*

$$e_t = (Z_t - \mu) - \phi(Z_{t-1} - \mu), \quad (2.11)$$

karena hanya  $Z_1, Z_2, \dots, Z_n$  yang diamati, maka kita hanya mendapatkan penjumlahan dari  $t=2$  sampai  $t=n$ , sebagai berikut

$$S_c(\phi, \mu) = \sum_{t=2}^n [(Z_t - \mu) - \phi(Z_{t-1} - \mu)]^2. \quad (2.12)$$

Persamaan diatas biasanya disebut sebagai fungsi *least square* bersyarat. Selanjutnya melakukan estimasi parameter  $\phi$  dan  $\mu$  dengan masing-masing nilai dari hasil meminimumkan  $S_c(\phi, \mu)$ . Pertama-tama persamaan (2.12) diturunkan terhadap  $\phi$  dan  $\mu$  dan

menyamakannya dengan nol sehingga akan diperoleh estimasi untuk kedua parameter tersebut adalah sebagai berikut

$$\hat{\mu} \approx \frac{1}{1-\phi} (\bar{Z} - \phi \bar{Z}) = \bar{Z} \quad (2.13)$$

dan

$$\hat{\phi} = \frac{\sum_{t=2}^n (Z_t - \bar{Z})(Z_{t-1} - \bar{Z})}{\sum_{t=2}^n (Z_{t-1} - \bar{Z})^2}. \quad (2.14)$$

### 2.2.3 Pengujian Signifikansi Parameter Model ARIMA

Setelah didapatkan estimasi parameter dari model ARIMA, maka parameter tersebut harus dilakukan pengecekan terhadap signifikansi parameter menggunakan kriteria uji  $t$ . Hipotesis yang digunakan untuk pengujian signifikansi parameter model AR( $p$ ) sebagai berikut

$$H_0 : \phi_i = 0,$$

$$H_1 : \phi_i \neq 0, i=1,2,\dots,p.$$

Statistik uji untuk parameter adalah

$$t_{hitung} = \frac{\hat{\phi}_i}{SE(\hat{\phi}_i)}. \quad (2.15)$$

Untuk hipotesis dalam pengujian signifikansi parameter model MA( $q$ ) sebagai berikut

$$H_0 : \theta_i = 0,$$

$$H_1 : \theta_i \neq 0, i=1,2,\dots,q.$$

Statistik uji untuk parameter adalah

$$t_{hitung} = \frac{\hat{\theta}_i}{SE(\hat{\theta}_i)}. \quad (2.16)$$

Dengan daerah kritis atau daerah penolakan adalah tolak  $H_0$  apabila  $|t_{hitung}| > t_{(\alpha/2; df=n-n_p)}$  atau  $P_{value} < \alpha$  yang menunjukkan

bahwa parameter  $\phi$  dan  $\theta$  dalam model sudah signifikan (Bowerman & O'Connell, 1993).

#### 2.2.4 Uji Kesesuaian Model ARIMA

Untuk mendapatkan model ARIMA terbaik, setelah mengestimasi dan menguji signifikansi semua parameter, adapula asumsi yang harus dipenuhi terhadap residual yaitu uji *white noise* (independen dan identik), dan uji distribusi normal.

##### 1. Uji Asumsi *White Noise* (independen)

Untuk menguji asumsi *white noise* dapat dilakukan menggunakan uji *Ljung-Box* atau *Box-Pierce Modified* (Wei, 2006). Adapun hipotesis yang akan digunakan dalam pengujian sebagai berikut

$$H_0 : \rho_1 = \rho_2 = \dots = \rho_K = 0,$$

$$H_1 : \text{minimal ada satu } \rho_k \neq 0, k = 1, 2, \dots, K.$$

Statistik uji yang digunakan dalam pengujian ini adalah

$$Q = n(n+2) \sum_{k=1}^K \frac{\hat{\rho}_k^2}{n-k} \quad (2.17)$$

dengan  $n$  merupakan jumlah pengamatan dan  $\hat{\rho}_k$  merupakan autokorelasi residual lag ke- $k$ . Adapun daerah kritis adalah tolak  $H_0$  apabila nilai  $Q > \chi_{\alpha; (K-M)}^2$  atau  $P_{value} < \alpha$  yang menunjukkan bahwa residual tidak memenuhi asumsi *white noise*. Dalam hal ini  $M$  adalah jumlah parameter orde ARMA ( $p, q$ ).

##### 2. Uji Asumsi *White Noise* (identik)

Uji *Lagrange Multiplier* adalah pengujian untuk melihat apakah residual ada efek ARCH (*Autoregressive Conditional Heteroscedasticity*) atau GARCH (*Generalized Autoregressive Conditional Heteroscedasticity*). Jika terdapat efek tersebut, maka varians residual masih belum konstan. Adapun hipotesis pengujian yang akan digunakan dalam pengujian sebagai berikut

$H_0$  : residual tidak terdapat efek ARCH atau GARCH (varians konstan),

$H_1$  : residual terdapat efek ARCH atau GARCH(varians belum konstan).

Statistik uji yang digunakan dalam pengujian ini adalah

$$Q^* = n(n+2) \sum_{l=1}^L \frac{\hat{\rho}_l^{*2}}{n-l}. \quad (2.18)$$

Dimana  $\hat{\rho}^*$  adalah nilai ACF dari  $e_t^2$ . Daerah kritis adalah tolak  $H_0$  apabila nilai  $Q^* > \chi_{\alpha; (L)}^2$  yang menunjukkan varians residual belum konstan (Enders, 2015).

### 3. Uji Asumsi Distribusi Normal

Uji asumsi distribusi normal dilakukan untuk mengetahui apakah residual berdistribusi normal atau tidak. Pengujian dilakukan menggunakan uji *Kolmogorov Smirnov*. Hipotesis yang akan digunakan sebagai berikut

$H_0$  : residual mengikuti distribusi normal,

$H_1$  : residual tidak mengikuti distribusi normal.

Statistik uji yang digunakan dalam pengujian ini adalah

$$D = \sup_x |S(e_t) - F_0(e_t)| \quad (2.19)$$

dengan  $S(e_t)$  adalah nilai kumulatif distribusi empiris dan  $F_0(e_t)$  adalah nilai kumulatif distribusi normal. Dengan daerah kritis tolak  $H_0$  jika  $D > D_\alpha$  tabel atau  $P_{value} < \alpha$  (Daniel, 2005).

### 2.3 Regresi *Time Series*

Secara umum, analisis regresi time series memiliki kesamaan bentuk model dengan model regresi linier. Yaitu dengan mengasumsikan bahwa respon adalah *dependent series* yang dipengaruhi oleh beberapa kemungkinan prediktor atau *independent series*, dimana input adalah variabel fix dan diketahui. Hubungan antara respon dan prediktor tersebut dapat diekspresikan dalam model regresi linier (Shumway & Stoffer,

2006). Apabila terdapat pengaruh tren pada data, maka model dapat diberikan pada persamaan berikut,

$$Z_t = \beta_1 t + w_t \quad (2.20)$$

dimana  $t=1,2,\dots,n$  dan  $w_t$  adalah *error* yang seharusnya memenuhi asumsi *white noise* atau independen, identik serta berdistribusi normal dengan mean 0 dan varian  $\sigma_w^2$ .

Dengan cara yang sama, data dengan penambahan variabel *dummy* berupa banyaknya bulan dalam satu tahun dapat juga dimodelkan dengan regresi. Model regresi linier untuk data dengan penambahan variabel *dummy* adalah sebagai berikut,

$$Z_t = \beta_1 D_{1,t} + \beta_2 D_{2,t} + \dots + \beta_p D_{p,t} + w_t \quad (2.21)$$

dimana  $D_{p,t}$  adalah variabel *dummy*,  $p$  mulai dari 1 hingga 12 sesuai jumlah bulan. Untuk mengetahui bahwa *error* telah *white noise* maka dapat dilakukan dengan uji Ljung-Box dan LM.

### 2.3.1 Estimasi Parameter Model Regresi

Estimasi parameter regresi time series sama halnya dengan estimasi parameter regresi linier. Metode estimasi yang digunakan adalah metode OLS (*ordinary least square*) atau metode kuadrat terkecil. Metode OLS mengestimasi nilai  $\beta_0, \beta_1, \beta_2, \dots, \beta_p$  dengan cara meminimumkan nilai

$$\sum_{t=1}^n \hat{w}_t^2 = \hat{\mathbf{w}}' \hat{\mathbf{w}} = \mathbf{Z}' \mathbf{Z} - 2 \hat{\boldsymbol{\beta}}' \mathbf{D}' \mathbf{Z} + \hat{\boldsymbol{\beta}} \mathbf{D}' \mathbf{D} \hat{\boldsymbol{\beta}}' \quad (2.22)$$

$$\mathbf{Z} = \begin{bmatrix} Z_1 \\ Z_2 \\ \vdots \\ Z_n \end{bmatrix}_{(n \times 1)} \quad \mathbf{D} = \begin{bmatrix} 1 & 0 & \dots & 0 \\ 0 & 1 & \dots & 0 \\ 0 & 0 & \dots & \vdots \\ 0 & 0 & \dots & 1 \end{bmatrix}_{(n \times p)}$$

jika

$$\frac{\partial(\hat{\mathbf{w}}' \hat{\mathbf{w}})}{\partial \hat{\boldsymbol{\beta}}} = -2 \mathbf{D}' \mathbf{Z} + 2 \mathbf{D}' \mathbf{D} \hat{\boldsymbol{\beta}} = 0 \quad (2.23)$$

maka dengan menyelesaikan persamaan (2.23) didapatkan hasil estimasi parameternya sebagai berikut

$$\hat{\beta} = (\mathbf{D}'\mathbf{D})^{-1}\mathbf{D}'\mathbf{Z}. \quad (2.24)$$

Setelah didapatkan nilai estimasi parameter model regresi, selanjutnya dilakukan uji signifikansi parameter.

### 2.3.2 Pengujian Signifikansi Parameter Model Regresi *Time Series*

Pengujian signifikansi parameter pada model Regresi *Time Series* pada dasarnya sama dengan Regresi linier. Dimana terdapat dua pengujian yaitu pengujian secara serentak dan parsial. Berikut adalah hipotesis yang digunakan pada pengujian serentak.

$$H_0 : \beta_1 = \beta_2 = \dots = \beta_p = 0,$$

$$H_1 : \text{minimal ada satu } \beta_i \neq 0, i=1,2,\dots,p.$$

Statistik uji yang digunakan dalam pengujian ini adalah uji F

$$F = \frac{RK_{regresi}}{RK_{residual}} \quad (2.25)$$

dimana,

**Tabel 2.2 ANOVA**

Sumber variansi	Derajat bebas	Jumlah kuadrat	Rata-rata kuadrat (RK)
Regresi	$p$	$\beta'\mathbf{D}'\mathbf{Z} - n\bar{Z}^2$	$\beta'\mathbf{D}'\mathbf{Z} - n\bar{Z}^2 / p$
Residual	$n - (p + 1)$	$\mathbf{Z}'\mathbf{Z} - \beta'\mathbf{D}'\mathbf{Z}$	$\mathbf{Z}'\mathbf{Z} - \beta'\mathbf{D}'\mathbf{Z} / n - (p + 1)$
Total	$n - 1$	$\mathbf{Z}'\mathbf{Z} - n\bar{Z}^2$	-

bila nilai  $F > F_{(\alpha, p, n-p-1)}$ , maka diambil keputusan tolak  $H_0$ .

Sedangkan untuk pengujian parsial hipotesisnya adalah sebagai berikut.

$$H_0 : \beta_i = 0,$$

$$H_1 : \beta_i \neq 0, i=1,2,\dots,p.$$

Statistik uji yang biasa digunakan adalah menggunakan distribusi  $t$  dengan persamaan sebagai berikut

$$T = \frac{\hat{\beta}_i}{SE(\hat{\beta}_i)}. \quad (2.26)$$

Bila  $T$  lebih besar dari  $t_{(\alpha/2; df; n-p)}$ , maka  $H_0$  akan ditolak. Begitu juga sebaliknya, bila  $T$  lebih kecil dari  $t_{(\alpha/2; df; n-p)}$ , maka akan diambil keputusan gagal tolak  $H_0$  (Walpole, 2010).

### 2.3.3 Pengujian Asumsi Residual

Dalam pemodelan regresi, asumsi residual yang harus terpenuhi adalah residual  $IIDN \sim (0, \sigma^2)$ . dimana artinya residual harus bersifat identik, independen, dan berdistribusi normal. Metode yang digunakan sama halnya yang telah dijelaskan pada metode ARIMA pada bagian 2.2.4 tentang uji kesesuaian model.

Jika residual tidak independen atau *white noise* maka model regresi akan ditambahkan *lag* yang signifikan berdasarkan pada plot ACF sebagai variabel independen. Sedangkan jika residual tidak memenuhi asumsi distribusi normal, maka akan dilakukan deteksi *outlier* dan kemudian menambahkan *outlier* kedalam model regresi. Deteksi *outlier* dilakukan dengan melihat nilai *deleted(studentized) residual*. Pengamatan dengan nilai *deleted residual* lebih dari -2 atau 2 dinyatakan sebagai *outlier*. Berikut adalah rumus untuk mendapatkan nilai *deleted residual*.

$$t_i^* = \frac{w_i}{\sqrt{s_{(i)}^2(1-h_i)}} = w_i \sqrt{\frac{n-p-1}{SSE(1-h_i) - w_i^2}} \quad (2.27)$$

dengan

$w_i$  : residual ke- $t$

$h_i$  : elemen diagonal ke- $t$  dari matriks  $\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'$

$n$  : jumlah pengamatan

$s_i^2$  :  $MSE$  yang dihitung setelah menghilangkan pengamatan ke- $t$

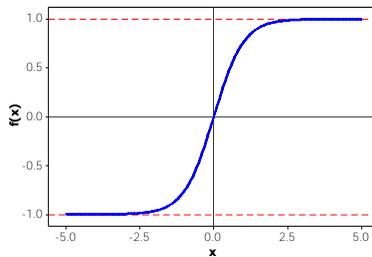
$MSE$  : rata-rata jumlah kuadrat terkecil  
 $SSE$  : jumlah kuadrat terkecil  
 $p$  : jumlah parameter dalam model.

## 2.4 Model Recurrent Neural Network (RNN)

Model RNN merupakan salah satu jenis *artificial neural network* dengan koneksi yang tidak hanya satu kali *feed-forward*, tetapi membentuk siklus (Bone & Cardot, 2011). Pada model RNN output yang dihasilkan digunakan sebagai input untuk mendapatkan output selanjutnya. Struktur model RNN terdiri dari *neurons* yang membentuk *input layer*, *hidden layer* dan *output layer*. Keeratan hubungan antar *neuron* dinyatakan dengan *weight*. Data pada *hidden layer* diproses menggunakan fungsi aktivasi. Terdapat beberapa fungsi aktivasi yang dapat digunakan. Pada penelitian ini digunakan salah satu fungsi aktivasi nonlinier, yaitu *tangent sigmoid* dengan persamaan berikut

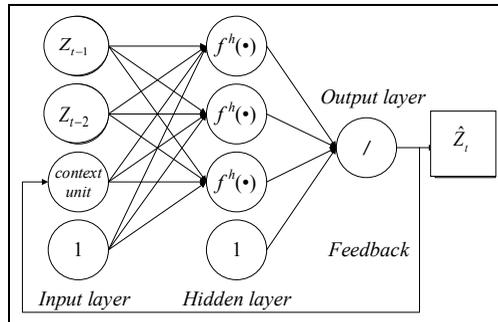
$$f^h(x) = \frac{2}{1 + e^{-2x}} - 1. \quad (2.28)$$

Fungsi  $f^h(x)$  memiliki nilai minimum -1 dan maksimum 1. Fungsi *tangent sigmoid* tersebut dapat digambarkan seperti pada Gambar 2.1.



**Gambar 2.1** Fungsi *Tangent Sigmoid*.

Salah satu jenis model RNN adalah Jordan-RNN. Contoh gambar struktur model Jordan-RNN adalah seperti pada Gambar 2.2 (Balkin, 1997).



**Gambar 2.2** Struktur Model Jordan-RNN (2,3,1)

Bentuk umum model RNN adalah sebagai berikut (Suhartono & Endharta, 2009)

$$\hat{Z} = f^o \left[ b_o + \sum_{j=1}^{n_h} \left( b_j f^h \left( \gamma_{j0} + \sum_{i=1}^{n_x} \gamma_{ji} X_i \right) \right) \right] \quad (2.29)$$

dengan

$b_j$  : *weight* unit ke- $j$  pada *hidden layer*

$\gamma_{ji}$  : *weight* dari input ke- $i$  menuju unit ke- $j$  pada *hidden layer*

$f^h(x)$  : fungsi aktivasi pada *hidden layer*

$f^o(x)$  : fungsi aktivasi pada *output layer*

$n_x$  : banyaknya variabel input

$n_h$  : banyaknya unit pada *hidden layer*.

Nilai *weight* dan bias dapat diestimasi dengan meminimumkan nilai  $E$  pada persamaan berikut (Chong & Zak, 2001)

$$E = \frac{1}{2} \sum_{t=1}^n [Z_t - \hat{Z}_t]^2 \quad (2.30)$$

Untuk meminimumkan  $E$ , digunakan metode *gradient descent* dengan momentum  $m$ , dimana  $0 < m < 1$ . Persamaannya adalah

$$w^{(t+1)} = w^{(t)} - \left( m.dw^{(t)} + (1-m)\eta \frac{\partial E}{\partial w} \right) \quad (2.31)$$

dengan  $dw$  adalah perubahan *weight* atau bias,  $\eta$  adalah *learning rate*, dengan  $0 < \eta < 1$ . Untuk menyelesaikan persamaan tersebut,  $E$  diturunkan secara parsial terhadap *weight* dan bias. Hasil penurunan parsial  $E$  terhadap masing-masing parameter adalah sebagai berikut

$$\frac{\partial E}{\partial b_j} = - \sum_{t=1}^n \delta_{(t)}^o V_{j(t)} \quad (2.32)$$

$$\frac{\partial E}{\partial b_0} = - \sum_{t=1}^n \delta_{(t)}^o \quad (2.33)$$

$$\frac{\partial E}{\gamma_{ji}} = - \sum_{t=1}^n \delta_{(t)}^h X_{i(t)} \quad (2.34)$$

$$\frac{\partial E}{\gamma_{jo}} = - \sum_{t=1}^n \delta_{(t)}^h \quad (2.35)$$

dengan

$$\delta_{(t)}^o = \left[ Z_{(t)} - \hat{Z}_{(t)} \right] f^o \left( b_0 + \sum_{l=1}^{n_h} b_l V_{l(t)} \right)$$

$$\delta_{(t)}^h = \delta_{(t)}^o b_j f^h \left( \gamma_{lo} + \sum_{l=1}^{n_x} \gamma_{li} X_{i(t)} \right).$$

Berdasarkan hasil penurunan tersebut, maka *weight* dan bias pada *output layer* berturut-turut adalah

$$b_j^{(s+1)} = b_j^{(s)} - \left( m.dw^{(s)} + (m-1)\eta \sum_{t=1}^n \delta_{(t)}^o V_{j(t)} \right) \quad (2.36)$$

$$b_0^{(s+1)} = b_0^{(s)} - \left( m.dw^{(s)} + (m-1)\eta \sum_{t=1}^n \delta_{(t)}^o \right) \quad (2.37)$$

sedangkan *weight* dan bias pada *hidden layer* berturut-turut adalah

$$\gamma_{ji}^{(s+1)} = \gamma_{ji}^{(s)} - \left( m.dw^{(s)} + (m-1)\eta \sum_{t=1}^n \delta_{(t)}^h X_{i(t)} \right) \quad (2.38)$$

$$\gamma_{jo}^{(s+1)} = \gamma_{jo}^{(s)} - \left( m.dw^{(s)} + (m-1)\eta \sum_{t=1}^n \delta_{(t)}^h \right). \quad (2.39)$$

## 2.5 Kriteria Pemilihan Model Terbaik

Pemilihan model terbaik terdiri dari dua pendekatan yaitu pendekatan *in sample* dan *out sample*. Pada penelitian ini model terbaik dipilih berdasarkan kriteria *out sample*. Salah satu kriteria *out sample* adalah *root mean squared error* (RMSE). RMSE digunakan untuk mengetahui akar rata-rata kesalahan kuadrat dan dihitung dengan rumus berikut (Wei, 2006)

$$RMSE = \sqrt{\frac{1}{L} \sum_{l=1}^L e_l^2} \quad (2.40)$$

dengan

$L$  : banyaknya data *out sample*

$e_l$  :  $Z_{n+l} - \hat{Z}_n(l)$

$Z_{n+l}$  : nilai pengamatan  $l$  step ke depan

$\hat{Z}_n(l)$  : ramalan  $l$  step ke depan.

## 2.6 Uji Nonlinieritas

Uji Terasvirta merupakan uji deteksi nonlinieritas yang dikembangkan berdasarkan model neural network dan termasuk dalam kelompok uji tipe Lagrange Multiplier dengan ekspansi

Taylor (Terasvirta, Lin, & Granger, 1993). Hipotesis yang digunakan dalam uji ini adalah

- $H_0$  :  $f(X)$  adalah fungsi linier dalam  $X$  (model linier),  
 $H_1$  :  $f(X)$  adalah fungsi nonlinier dalam  $X$  (model nonlinier).

Statistik uji yang digunakan dalam pengujian ini adalah

$$F = \frac{(SSR_0 - SSR) / m}{SSR / (N - r - 1 - m)} \quad (2.41)$$

dengan

$SSR_0$  : jumlah kuadrat *error* dari regresi  $f(X)$  dengan  $X$  dimana menghasilkan residual  $u_t$

$SSR$  : jumlah kuadrat *error* dari regresi  $u_t$  dengan  $X$  dan  $m$

$r$  : jumlah variabel prediktor awal

$m$  : jumlah variabel prediktor kuadrat dan kubik

$N$  : jumlah data.

Daerah kritis adalah tolak  $H_0$  apabila  $F$  lebih besar dari nilai  $F_{tabel}$  dengan derajat bebas  $m$  dan  $N-r-1-m$ , maka  $f(X)$  merupakan fungsi nonlinier dalam  $X$ .

## 2.7 Penanggalan Sasih Bali (Tahun Saka)

Kalender atau penanggalan Bali sangat penting dalam kehidupan sehari-hari masyarakat Bali. Tidak seperti kalender lain yang banyak macamnya di dunia, kalender Bali bisa dikatakan istimewa. Penanggalan Bali adalah penanggalan konvensional, dalam artian dalam penentuan penanggalannya tidak astronomis dan tidak pula aritmatik seperti penanggalan Jawa, tetapi kira-kira ada di antara keduanya. Penanggalan Bali mirip penanggalan luni-solar, karena perhitungannya berdasarkan posisi matahari (*Surya*) dan sekaligus posisi bulan (*Candra*). Dalam penentuan awal sudah disepakati bahwa 1 hari *Candra* = 1 hari *Surya*. Namun kenyataannya 1 hari *Candra* tidak sama dengan panjang dari 1 hari *Surya*. Untuk itu setiap 63 hari (9 *wuku*) ditetapkan satu hari *Surya* yang nilainya sama dengan dua hari *Candra*. Hari ini dinamakan *pangunalatri*. Hal ini tidak sulit diterapkan dalam teori aritmatika. Derajat ketelitiannya cukup

bagus, hanya memerlukan 1 hari koreksi dalam seratusan tahun. Dalam 1 bulan *Candra* atau *sasih*, disepakati ada 30 hari terdiri dari 15 hari menjelang bulan penuh (*purnama*) disebut *penanggal* atau *suklapaksa*, diikuti dengan 15 hari menjelang bulan mati (*tilem*) disebut *panglong* atau *kresnakapsa*.

Panjang bulan *Surya* juga tidak sama dengan panjang *sasih* (bulan *Candra*). *Sasih* panjangnya berfluktuasi tergantung kepada jarak bulan dengan bumi dalam orbit elipsnya. Sehingga kurun tahun *Surya* kira-kira 11 hari lebih panjang dari tahun *Candra*. Untuk menyelaraskan itu, setiap kira-kira 3 tahun *Candra* disisipkan satu *sasih* tambahan. Penambahan *sasih* ini masih agak rancu peletakannya. Inilah tantangan bagi dunia aritmatika. Idealnya awal tahun *surya* jatuh pada paruh-akhir *sasih* keenam (*Kanem*) atau paruh awal *sasih* ketujuh (*Kapitu*), sehingga tahun baru *Saka* (hari raya Nyepi) selalu jatuh di sekitar paruh bulan Maret pada kalender masehi (Babad Bali, 2010).

Selain sebagai penentuan hari raya, penanggalan Bali juga erat kaitannya dengan aktivitas kehidupan sehari-hari salah satunya dibidang pertanian dalam penentuan pola tanam (Kec. Penebel, 2013). Dalam penentuan pola tanam ini dijelaskan tahapan-tahapan pertanian khususnya padi sesuai penanggalan *sasih*. Berikut adalah beberapa gambar penanggalan yang digunakan sebagai acuan pola pertanian di Bali.



**Gambar 2.3** Penanggalan Bali untuk Bidang Pertanian

Jika diringkas dan diterjemahkan, maka secara singkat pola pertanian di Bali berdasarkan penanggalan sasih dapat dilihat pada Tabel 2.3.

**Tabel 2.3** Pola Tanam Pertanian Berdasarkan Penanggalan Sasih

<i>Sasih</i>	Bulan	Kegiatan
<i>Kasa</i>	Juli	<i>Manyi</i> , yaitu kegiatan memanen padi
<i>Karo</i>	Agustus	Upacara <i>Mantenin</i> , yaitu upacara menaikkan atau menyimpan padi ke lumbung.
<i>Katiga</i>	September	Upacara <i>Mapag Toya</i> , yaitu upacara menjemput air ke sumber mata air. <i>Kempelan</i> , yaitu kegiatan membuka saluran air ke sumber aliran air di hulu subak, selanjutnya air mengalir sawah. Upacara <i>Ngendag Tanah Carik</i> , yaitu upacara memohon keselamatan kepada Tuhan saat membajak tanah sawah dan dilakukan oleh masing-masing anggota subak.
<i>Kapat</i>	Oktober	-
<i>Kalima</i>	November	Upacara <i>Ngurit</i> , yaitu upacara pembibitan yang dilakukan oleh semua anggota subak pada masing-masing tanah garapannya.
<i>Kanem</i>	Desember	-
<i>Kapitu</i>	Januari	Upacara <i>Ngerasakin</i> , yaitu upacara membersihkan kotoran ( <i>leteh</i> ) yang tertinggal ketika melakukan pembajakan sawah dan dilakukan setelah pembajakan selesai di masing-masing tanah garapan. Upacara <i>Pangawiwit (Nuwasen)</i> , yaitu upacara mencari hari baik untuk mulai menanam padi.
<i>Kawulu</i>	Februari	Upacara <i>Ngekambuhin</i> , yaitu upacara meminta keselamatan anak padi yang baru tumbuh yang dilakukan pada saat padi berumur 42 hari.
<i>Kasanga</i>	Maret	Upacara <i>Penyepian</i> , yaitu upacara memohon keselamatan agar tanaman padi terhindar dari hama/penyakit. <i>Pengerestitian Nyegara Gunung</i> , yaitu melaksanakan upacara nyegara gunung yang dilakukan di Pura Luhur Petali dan Pura Luhur Pekendungan.
<i>Kadasa</i>	April	Upacara <i>Mesaba</i> , yaitu upacara sebelum panen.
<i>Desta</i>	Mei	-
<i>Sada</i>	Juni	Upacara <i>nganyarin</i> , yaitu upacara mulai panen yang dilakukan anggota subak.

## 2.8 Pola Tanam

Pola tanam di daerah tropis, biasanya disusun selama satu tahun dengan memperhatikan curah hujan, terutama pada daerah atau lahan yang sepenuhnya tergantung dari hujan. Maka pemilihan jenis/varietas yang ditanam perlu disesuaikan dengan keadaan air yang tersedia ataupun curah hujan. Pola tanam terbagi dua yaitu pola tanam monokultur dan pola tanam polikultur. Pertanian monokultur adalah pertanian dengan menanam tanaman sejenis. Misalnya sawah ditanami padi saja, jagung saja, atau kedelai saja. Tujuan menanam secara monokultur adalah meningkatkan hasil pertanian. Sedangkan pola tanam polikultur ialah pola pertanian dengan banyak jenis tanaman pada satu bidang lahan yang terusun dan terencana dengan menerapkan aspek lingkungan yang lebih baik (Wahyudi, 2013).

## 2.9 Curah Hujan

Menurut Purnomo (2011) iklim menunjukkan kondisi umum atau kondisi rata-rata dari unsur-unsur cuaca dalam waktu relatif panjang meliputi kurun waktu beberapa bulan atau beberapa tahun pada lokasi lebih luas. *Intergovernment Panel on Climate Change* (IPCC) tahun 2007 menyatakan iklim merupakan rata-rata dan variansi temperatur, penguapan, presipitasi (curah hujan) dan angin selama periode tertentu yang berkisar dalam hitungan bulan hingga jutaan tahun. Unsur iklim yang terpenting adalah curah hujan karena curah hujan di Indonesia memiliki keragaman yang cukup tinggi.

Curah hujan adalah jumlah air yang jatuh di permukaan tanah datar selama periode tertentu yang diukur dengan satuan tinggi (mm) di atas permukaan horizontal bila tidak terjadi evaporasi, *runoff* dan infiltrasi. Satuan curah hujan adalah mm atau inch. Arti dari curah hujan 1 milimeter adalah dalam luasan satu meter persegi pada tempat yang datar tertampung air setinggi satu millimeter atau tertampung air sebanyak satu liter. Curah hujan kumulatif (mm) merupakan jumlah hujan yang terkumpul dalam rentang waktu kumulatif tersebut. Dalam periode musim,

rentang waktu curah hujan adalah rata-rata panjang musim pada masing-masing daerah prakiraan Musim (Mangostina, 2010).

## BAB III METODOLOGI PENELITIAN

### 3.1 Sumber Data dan Variabel Penelitian

Pada penelitian ini, data yang digunakan adalah data sekunder. Data sekunder diperoleh dari Badan Meteorologi Klimatologi dan Geofisika (BMKG) Wilayah III Provinsi Bali dari tahun 1990-2014. Sedangkan untuk variabel penelitian yang akan digunakan dalam penelitian ini adalah data curah hujan salah satu stasiun BMKG Provinsi Bali dari tahun 1990-2014. Stasiun yang dimaksud berada di sekitar daerah Jatiluwih, Tabanan.

Pada metode Regresi *Time Series*, peramalan curah hujan dimodelkan dengan memasukkan pengaruh variabel eksogen. Variabel eksogen memiliki skala nominal sehingga dinyatakan dengan variabel *dummy*. Variabel eksogen adalah pengaruh musiman bulanan yang dinyatakan sebagai berikut

$$D_{1,t} = \begin{cases} 1, & \text{jika bulan ke-}t \text{ adalah bulan Januari} \\ 0, & \text{jika bulan ke-}t \text{ bukan bulan Januari} \end{cases}$$
$$D_{2,t} = \begin{cases} 1, & \text{jika bulan ke-}t \text{ adalah bulan Februari} \\ 0, & \text{jika bulan ke-}t \text{ bukan bulan Februari} \end{cases}$$
$$D_{3,t} = \begin{cases} 1, & \text{jika bulan ke-}t \text{ adalah bulan Maret} \\ 0, & \text{jika bulan ke-}t \text{ bukan bulan Maret} \end{cases}$$
$$D_{4,t} = \begin{cases} 1, & \text{jika bulan ke-}t \text{ adalah bulan April} \\ 0, & \text{jika bulan ke-}t \text{ bukan bulan April} \end{cases}$$
$$D_{5,t} = \begin{cases} 1, & \text{jika bulan ke-}t \text{ adalah bulan Mei} \\ 0, & \text{jika bulan ke-}t \text{ bukan bulan Mei} \end{cases}$$
$$D_{6,t} = \begin{cases} 1, & \text{jika bulan ke-}t \text{ adalah bulan Juni} \\ 0, & \text{jika bulan ke-}t \text{ bukan bulan Juni} \end{cases}$$
$$D_{7,t} = \begin{cases} 1, & \text{jika bulan ke-}t \text{ adalah bulan Juli} \\ 0, & \text{jika bulan ke-}t \text{ bukan bulan Juli} \end{cases}$$

$$D_{8,t} = \begin{cases} 1, & \text{jika bulan ke-}t \text{ adalah bulan Agustus} \\ 0, & \text{jika bulan ke-}t \text{ bukan bulan Agustus} \end{cases}$$

$$D_{9,t} = \begin{cases} 1, & \text{jika bulan ke-}t \text{ adalah bulan September} \\ 0, & \text{jika bulan ke-}t \text{ bukan bulan September} \end{cases}$$

$$D_{10,t} = \begin{cases} 1, & \text{jika bulan ke-}t \text{ adalah bulan Oktober} \\ 0, & \text{jika bulan ke-}t \text{ bukan bulan Oktober} \end{cases}$$

$$D_{11,t} = \begin{cases} 1, & \text{jika bulan ke-}t \text{ adalah bulan November} \\ 0, & \text{jika bulan ke-}t \text{ bukan bulan November} \end{cases}$$

$$D_{12,t} = \begin{cases} 1, & \text{jika bulan ke-}t \text{ adalah bulan Desember} \\ 0, & \text{jika bulan ke-}t \text{ bukan bulan Desember.} \end{cases}$$

### 3.2 Langkah Analisis

Langkah analisis yang dilakukan pada penelitian ini berdasarkan tujuan penelitian adalah sebagai berikut.

1. Melakukan analisis statistika deskriptif tentang kondisi curah hujan yang terjadi selama ini.
2. Melakukan validasi pola pertanian berdasarkan penanggalan sah dengan kondisi curah hujan yang terjadi selama ini.
3. Melakukan pemodelan atau peramalan curah hujan
  - a. Regresi *Time Series*.
    - i. Membagi data curah hujan kedalam *in sampel* dan *out sampel*, dimana data *in sampel* dari tahun 1990-September 2013 dan data *out sampel* dari Oktober 2013-September 2014.
    - ii. Melakukan pemodelan *Time Series Regression* untuk data curah hujan dengan respon adalah data curah hujan dan prediktor adalah variabel *dummy* bulanan.
    - iii. Jika residual belum memenuhi asumsi *white noise* maka akan dilakukan penambahan orde AR kedalam model regresi sehingga akan terdapat

tambahan variabel prediktor. Sedangkan jika belum memenuhi asumsi distribusi normal maka akan dilakukan deteksi *outlier*.

- b. ARIMA.
  - i. Membagi data curah hujan kedalam *in sampel* dan *out sampel*, dimana data *in sampel* dari tahun 1990-September 2013 dan data *out sampel* dari Oktober 2013-September 2014.
  - ii. Menguji stasioner atau tidaknya kondisi data curah hujan.
  - iii. Mendapatkan prakiraan model berdasarkan plot ACF dan PACF.
  - iv. Mendapatkan estimasi parameter dari model yang sudah dibentuk.
  - v. Melakukan uji asumsi *white noise* dan distribusi normal terhadap error yang terbentuk.
  - vi. Melakukan uji signifikansi parameter.
- c. RNN.
  - i. Menentukan input untuk model RNN berdasarkan model terbaik (*Time series regression* dan SARIMA)
  - ii. Melakukan *preprocessing* data dengan rumus berikut.

$$Z_t^* = \frac{2[Z_t - \min(Z)]}{[\max(Z) - \min(Z)]} - 1 \quad (3.1)$$

dengan  $t=1,2,\dots,n$

- iii. Menentukan fungsi aktivasi yang digunakan.
- iv. Menentukan jumlah unit pada *hidden layer* dengan mencoba menggunakan 1 sampai 10 unit.
- v. Melakukan *postprocessing* dengan rumus berikut.

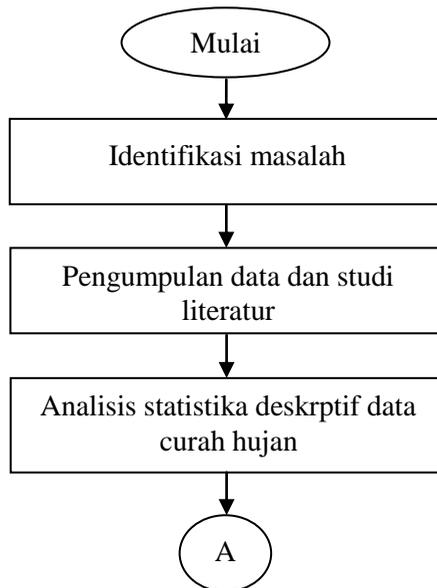
$$Z_t = \frac{(Z_t^* + 1)[\max(Z) - \min(Z)]}{2} + \min(Z) \quad (3.2)$$

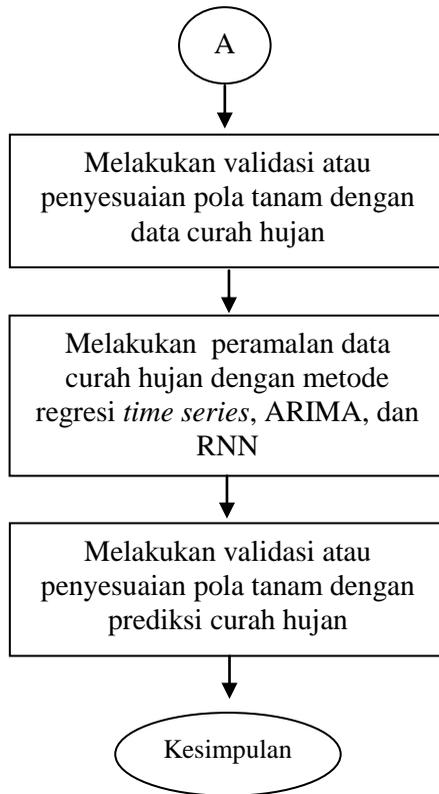
dengan  $t= 1,2,\dots,n$ .

- vi. Memilih model RNN terbaik, yaitu model dengan jumlah unit pada *hidden layer* yang menghasilkan RMSE *out sample* terkecil.
  - d. Melakukan peramalan curah hujan kedepannya dengan model terbaik berdasarkan kriteria RMSE *out sample*.
4. Melakukan validasi atau penyesuaian pola pertanian berdasarkan penanggalan *sasih* dengan kondisi curah hujan yang akan terjadi.

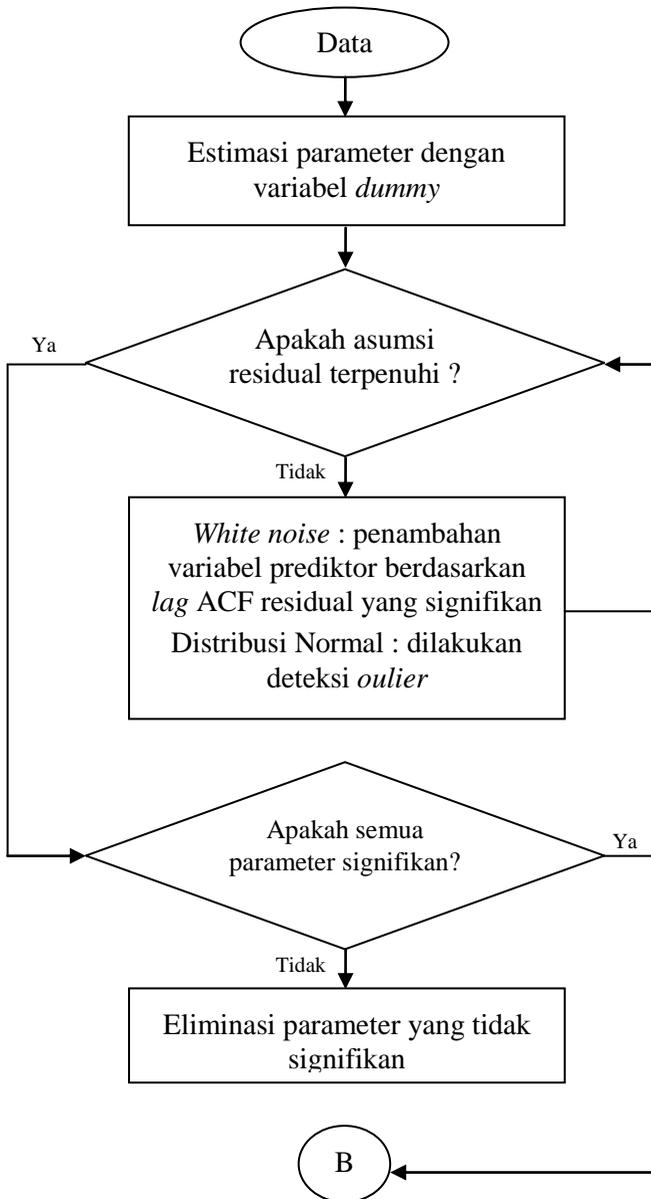
### 3.3 Diagram Alir

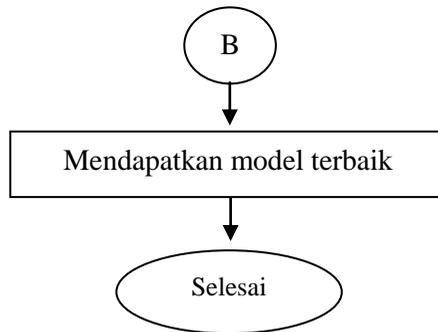
Berikut merupakan diagram alir dari langkah-langkah penelitian yang akan dilakukan.



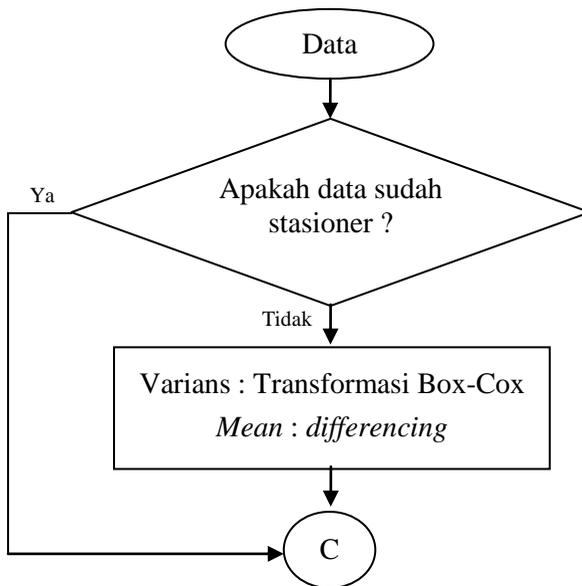


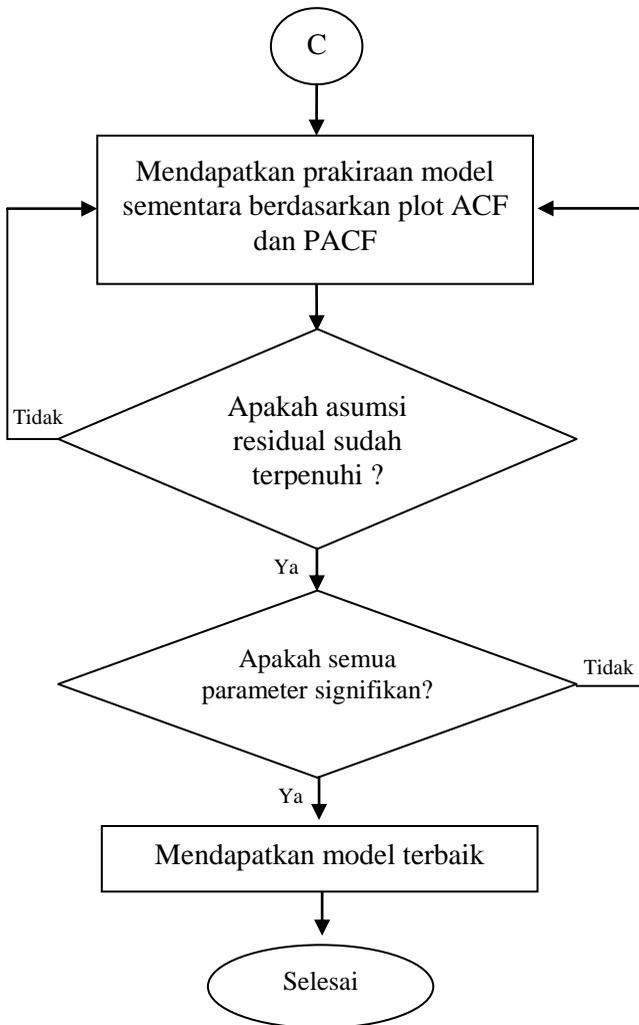
**Gambar 3.1** Langkah Analisis



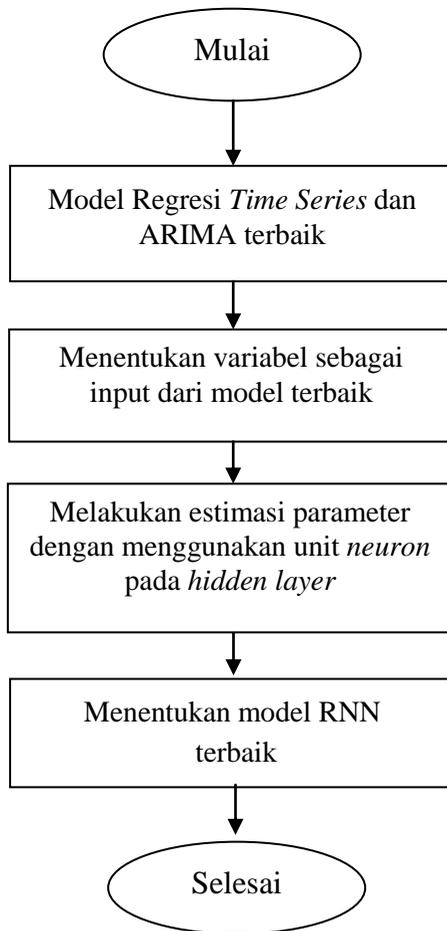


**Gambar 3.2** Langkah Analisis Metode Regresi *Time Series*





**Gambar 3.3** Langkah Analisis Metode ARIMA



**Gambar 3.4** Langkah Analisis Metode RNN

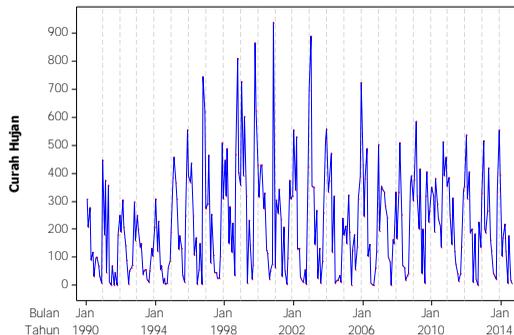
“Halaman ini sengaja dikosongkan”

## BAB IV ANALISIS DAN PEMBAHASAN

Pada bab ini dijelaskan hasil validasi pola pertanian dengan kondisi curah hujan di desa Jatiluwih, Kabupaten Tabanan. Analisis yang dilakukan meliputi deskripsi data, penyesuaian pola pertanian dengan kondisi curah hujan yang terjadi, pemodelan dengan *Time Series Regression*, ARIMA dan RNN, peramalan curah hujan dengan model terbaik serta penyesuaian pola pertanian dengan kondisi curah hujan yang akan terjadi.

### 4.1 Karakteristik Kondisi Curah Hujan dari Tahun 1990-2014 di Desa Jatiluwih

Karakteristik kondisi curah hujan di Desa Jatiluwih selama 25 tahun dijelaskan secara visual dengan plot *time series*.



**Gambar 4.1** Plot *Time Series* Kondisi Curah Hujan di Desa Jatiluwih Tahun 1990-2014

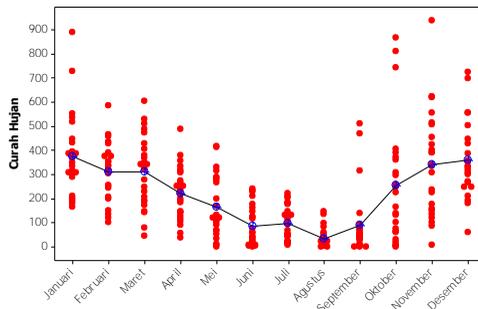
Dari Gambar 4.1 dapat dilihat bahwa kondisi curah hujan yang terjadi memiliki pola musiman. Dimana curah hujan cenderung tinggi mulai bulan Oktober hingga bulan April atau Mei dan terjadi penurunan pada bulan-bulan selanjutnya. Jika dilihat pola secara keseluruhan selama 25 tahun, dari tahun 1990 sampai tahun 1994 curah hujan yang terjadi cenderung konstan

tiap tahunnya. Namun selanjutnya mengalami peningkatan yang cukup terlihat sampai tahun 2000 dan terjadi penurunan intensitas curah hujan secara perlahan sampai tahun 2007. Semenjak tahun 2007 sampai tahun 2014 kondisi curah hujan yang terjadi tiap tahunnya cukup stabil atau konstan. Berikut adalah karakteristik curah hujan selama 25 tahun.

**Tabel 4.1** Karakteristik Data Curah Hujan

Mean	219,71
St. dev	185,63
Maksimal	936,00
Minimal	0,00
<i>Skweness</i>	1,03
<i>Kurtosis</i>	1,13

Rata-rata curah hujan selama 25 tahun sebesar 219,71 mm dengan standar deviasi sebesar 185,63. Sehingga jika melihat kondisi tersebut, semenjak tahun 1990 sampai tahun 2014 daerah Jatiluwih mendapatkan intensitas curah hujan yang cukup untuk kegiatan pertanian. Untuk melihat kondisi curah hujan tiap bulannya dapat dilihat pada Gambar 4.2.



**Gambar 4.2** *Individual Plot* Kondisi Curah Hujan tiap Bulannya

Gambar 4.2 menunjukkan bahwa terdapat pola musiman bulanan. Intensitas curah hujan pada bulan Januari menurut kategori BMKG, rata-rata menunjukkan kondisi menengah.

Kondisi tersebut cenderung konstan sampai bulan Maret dan mengalami penurunan yang cukup signifikan sampai bulan Agustus. Pada bulan September kondisi curah hujan mulai meningkat, dan pada bulan Oktober sampai Desember mengalami peningkatan yang signifikan. Namun pada bulan dan tahun tertentu terdapat beberapa kondisi dimana curah hujannya mengalami *outlier*.

#### 4.2 Penyesuaian Pola Pertanian Berdasarkan Penanggalan *Sasih* dengan Kondisi Curah Hujan yang Terjadi

Pada tahap ini akan dilihat kesesuaian pola pertanian berdasarkan penanggalan *sasih* jika dikaitkan dengan kondisi curah hujan yang terjadi. Untuk memudahkan analisis, curah hujan dikategorikan berdasarkan kategori dari BMKG sebagai berikut

**Tabel 4.2** Kategori Curah Hujan Berdasarkan BMKG

Curah Hujan (mm)	Warna	Keterangan
0-20		Rendah
21-50		
51-100		
101-150		Menengah
151-200		
201-300		
301-400		Tinggi
401-500		
>500		Sangat Tinggi

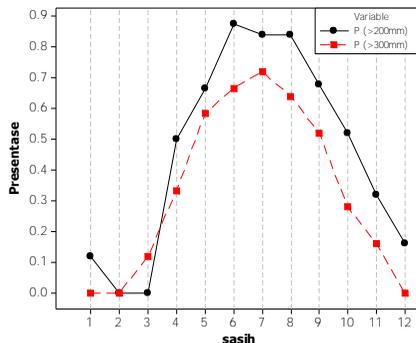
Berdasarkan Tabel 4.2, BMKG membagi kategori curah hujan di Indonesia kedalam 4 kategori, yaitu curah hujan rendah, curah hujan menengah, curah hujan tinggi, dan curah hujan sangat tinggi. Dalam tiap kategorinya curah hujan tersebut dibagi kembali seperti yang terlihat pada Tabel 4.2. Dalam hal ini, curah hujan untuk syarat memulai pertanian termasuk dalam kategori menengah. Sehingga untuk penyesuaiannya nanti hanya perlu

dilihat kesesuaian dari keterangan warna curah hujannya. Berikut adalah hasil kategori curah hujan di Desa Jatiluwih selama 25 tahun pengamatan.

**Tabel 4.3** Kondisi Curah Hujan di Desa Jatiluwih Tahun 1990-2014

Sasih	7	8	9	10	11	12	1	2	3	4	5	6
Masehi	1	2	3	4	5	6	7	8	9	10	11	12
1990												
1991												
1992												
1993												
1994												
1995												
1996												
1997												
1998												
1999												
2000												
2001												
2002												
2003												
2004												
2005												
2006												
2007												
2008												
2009												
2010												
2011												
2012												
2013												
2014												
n(rendah)	0	0	2	3	8	15	13	24	21	8	2	1
n(menengah)	7	9	9	15	13	10	12	1	1	8	8	7
n(tinggi)	13	15	11	7	4	0	0	0	2	5	8	11
n(sangat tinggi)	5	1	3	0	0	0	0	0	1	3	6	5
P (>200mm)	0,84	0,84	0,68	0,52	0,32	0,16	0,12	0	0	0,50	0,67	0,88
P (>300mm)	0,72	0,64	0,52	0,28	0,16	0	0	0	0	0,33	0,58	0,67

Berdasarkan tahapan pertanian dalam penanggalan *sasih*, proses penanaman bibit dimulai pada *sasih kapitu* atau bulan Januari. Jika melihat kondisi yang ada, maka pada *sasih kapitu* intensitas curah hujan yang terjadi minimal 151 mm. Namun sebagian besar intensitas curah hujan pada *sasih kapitu* diatas 200 mm. Syarat untuk memulai pertanian yang baik adalah kondisi curah hujan yang terjadi minimal 200 mm. Sehingga jika melihat kondisi curah hujan selama 25 tahun, pola pertanian berdasarkan penanggalan *sasih* hanya tidak tepat sebanyak empat kali. Hal tersebut terjadi pada musim tanam tahun 1991,1992, 2007, dan 2008. Meskipun musim tanam digeser lebih awal yaitu pada *sasih kanem*, masih ada kondisi dimana syarat minimal curah hujan tidak terpenuhi meskipun hanya terjadi kesalahan sebanyak tiga kali. Begitu juga jika musim tanam diundur pada *sasih kawulu*, masih ada kondisi dimana syarat minimal curah hujan belum terpenuhi. Berikut adalah persentase keberhasilan tiap bulan pada penanggalan *sasih* jika dikaitkan dengan dua kondisi curah hujan.

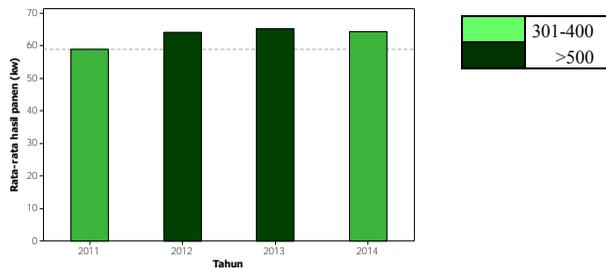


**Gambar 4.3** Persentase Keberhasilan Penanggalan *Sasih*

Berdasarkan Gambar 4.3 dapat dilihat jika kondisi curah hujan minimal 200 mm maka sebaiknya musim tanam dimulai pada *sasih kanem*. Hal tersebut dikarenakan proporsi atau persentase keberhasilan selama 25 tahun lebih tinggi dibanding *sasih* yang lain. Namun jika melihat kondisi curah hujan minimal 300 mm maka *sasih* yang paling tepat adalah *sasih kapitu* atau

sesuai dengan kalender tanam berdasarkan penanggalan *sasih*. Meskipun syarat minimal curah hujan untuk memulai pertanian sebesar 200 mm, namun semakin tinggi curah hujan juga memberikan dampak pada produktivitas pertanian.

Meskipun masih ada kesalahan dalam sistem penanggalan *sasih*, namun keakuratannya selama 25 tahun cukup tinggi. Dimana hanya melakukan empat kali kesalahan. Proporsi ketepatan penanggalan *sasih* dalam penentuan pola tanam jika dikaitkan dengan kondisi curah hujan yaitu sebesar 87,5%. Tentu nilai tersebut bukan nilai yang kecil. Selain itu, kondisi curah hujan pada saat *sasih kapitu* tahun 1991,1992, 2007, dan 2008 masih tergolong menengah. Sehingga penanggalan *sasih* masih relevan digunakan untuk penentuan pola tanam. Namun tentu masih perlu dilakukan evaluasi serta peningkatan sistem pertanian khususnya irigasi. Sehingga jika kondisi curah hujan yang terjadi tidak memenuhi syarat untuk memulai pertanian, dampaknya dapat diminalisir. Untuk melihat pengaruh sistem penanggalan *sasih* terhadap hasil produksi, dapat dilihat sebagai berikut

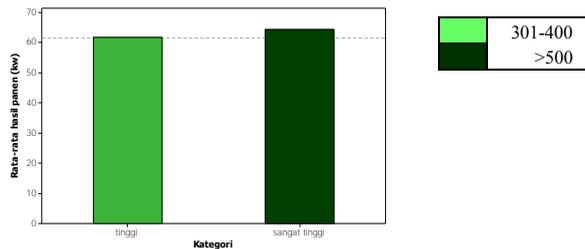


**Gambar 4.4** Rata-Rata Produktivitas Hasil Panen 2011-2014

Jika melihat secara keseluruhan, hasil panen di desa Jatiluwi Kecamatan Penebel dari tahun 2011 mengalami peningkatan namun terjadi penurunan pada tahun 2014. Penurunan yang terjadi dikarenakan dampak semakin berkurangnya luas tanam. Salah satu penyebabnya karena adanya alih fungsi lahan pertanian yang semakin marak terjadi di Bali.

Berdasarkan Gambar 4.4 pada tahun 2011 dan 2014, intensitas curah hujan yang terjadi pada *sasih kapitu* tergolong

tinggi. Sedangkan pada tahun 2012 dan 2013 dimana rata-rata hasil panen lebih tinggi dari pada tahun 2011 dan 2014 intensitas curah hujan yang terjadi pada *sasih kapitu* tergolong sangat tinggi. Sehingga secara deskriptif terlihat pengaruh curah hujan yang terjadi terhadap hasil panen. Berikut jika rata-rata hasil panen dikategorikan berdasarkan intensitas curah hujan pada *sasih kapitu*.



**Gambar 4.5** Rata-Rata Produktivitas Hasil Panen berdasarkan Kondisi Curah Hujan

Terlihat semakin tinggi curah hujan, maka produktivitas hasil panen semakin optimal. Sehingga penentuan *sasih kapitu* sebagai masa awal tanam sudah sesuai jika melihat Gambar 4.3, dimana *sasih kapitu* memiliki persentase paling besar turunnya curah hujan diatas 300 mm. Selain itu rata-rata hasil panen di desa Jatiluwih Kecamatan Penebel selalu lebih tinggi dari pada rata-rata hasil panen di tingkat Kabupatennya. Hal tersebut menunjukkan bahwa hasil panen didaerah Jatiluwih Kecamatan Penebel lebih optimal tiap tahunnya.

### 4.3 Peramalan Curah Hujan

Pada tahap ini, akan dilakukan peramalan curah hujan dengan metode *time series regression*, ARIMA, dan RNN. Data curah hujan dibagi menjadi *in sample* dan *out sample*. Dimana penentuan model akan menggunakan data *in sample*, sedangkan uji kebaikan model akan menggunakan data *out sample*. Data *in sample* ada sebanyak 285 data dimulai dari Januari 1990 sampai September 2013. Sisanya termasuk data *out sample*.

### 4.3.1 Model *Time Series Regression*

Berdasarkan Gambar 4.1, diketahui intensitas curah hujan dipengaruhi oleh waktu dalam hal ini adalah periode bulan. Untuk mengetahui pengaruh bulan pada intensitas curah hujan dilakukan pemodelan regresi *time series* dengan variabel *dummy* atau disebut dengan efek variasi kalender. Tahap awal yaitu memodelkan intensitas curah hujan dengan variabel *dummy* sesuai persamaan (2.20). Hasil estimasi parameter regresi *time series* dengan variabel *dummy* untuk intensitas curah hujan dapat dilihat pada Tabel 4.4.

**Tabel 4.4** Estimasi Parameter Regresi *Time Series*

Parameter	Estimasi	SE	T	P
$\beta_1$	373,73	30,15	12,39	0,00
$\beta_2$	321,29	30,15	10,66	0,00
$\beta_3$	317,52	30,15	10,53	0,00
$\beta_4$	221,44	30,15	7,34	0,00
$\beta_5$	166,92	30,15	5,54	0,00
$\beta_6$	89,58	30,15	2,97	0,00
$\beta_7$	93,48	30,15	3,10	0,00
$\beta_8$	36,46	30,15	1,21	0,22
$\beta_9$	92,71	30,15	3,07	0,00
$\beta_{10}$	263,85	30,80	8,57	0,00
$\beta_{11}$	342,35	30,80	11,11	0,00
$\beta_{12}$	351,30	30,80	11,41	0,00

Dari Tabel 4.4, dapat dilihat semua parameter telah signifikan kecuali  $\beta_8$ . Berikut adalah model matematis berdasarkan estimasi parameter yang telah dilakukan.

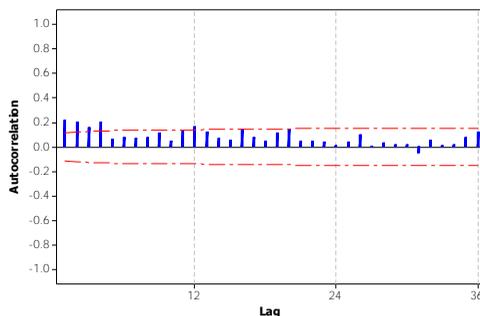
$$\begin{aligned}
 Z_t = & 373,73D_{1,t} + 321,29D_{2,t} + 317,52D_{3,t} + 221,44D_{4,t} \\
 & + 166,92D_{5,t} + 89,58D_{6,t} + 93,48D_{7,t} + 36,46D_{8,t} \\
 & + 92,71D_{9,t} + 263,85D_{10,t} + 342,35D_{11,t} + 351,30D_{12,t} + e_t.
 \end{aligned} \tag{4.1}$$

Selanjutnya dilakukan pengujian asumsi residual terlebih dahulu. Asumsi residual yang harus terpenuhi adalah residual yang *white noise* dan berdistribusi normal. Pertama akan diuji apakah residual sudah memenuhi asumsi *white noise*. Hasil pengujian *white noise* dapat dilihat pada Tabel 4.5.

#### 4.5 Uji Asumsi *White Noise* Model Regresi *Time Series*

Sampai lag ke-	Q	df	P
6	47,20	6	0,00
12	67,97	12	0,00
18	83,27	18	0,00
24	95,52	24	0,00
30	99,48	30	0,00

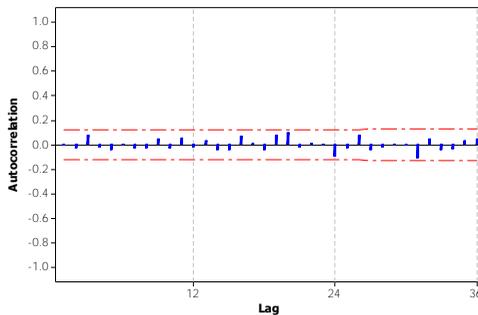
Dari Tabel 4.5 dapat diketahui bahwa model regresi belum memenuhi asumsi residual *white noise* karena nilai *P* kurang dari 0,1. Selain itu asumsi normalitas pada residual juga belum terpenuhi dengan nilai *skewness* 1,15 dan *kurtosis* 2,88. Oleh karena itu, model regresi tersebut perlu ditambahkan input variabel berdasarkan *lag-lag* yang signifikan pada plot ACF. Input variabel diidentifikasi dengan bantuan plot ACF residual pada Gambar 4.6.



**Gambar 4.6** Plot ACF Residual Model Regresi

Berdasarkan Gambar 4.6 dapat dilihat plot ACF dari residual model regresi. Pada plot ACF dapat dilihat *lag* 1,2,3,4, dan 12 bernilai signifikan. Sehingga ada beberapa kemungkinan input variabel yang akan didapatkan, mulai dari  $Z_{t-1}$ ,  $Z_{t-2}$ ,  $Z_{t-3}$ ,  $Z_{t-4}$ , dan  $Z_{t-12}$ . Dimana input variabel atau *lag* tersebut akan ditambahkan pada model regresi. Sehingga akan didapatkan nilai residual yang telah memenuhi asumsi *white noise*. Penambahan input variabel tersebut dilakukan secara bertahap hingga didapatkan residual yang telah memenuhi asumsi *white noise*. Berikut adalah model sementara yang dimana asumsi *white noise* telah terpenuhi berdasarkan plot ACF pada Gambar 4.7.

$$\begin{aligned}
 Z_t = & 215,96D_{1,t} + 143,16D_{2,t} + 129,55D_{3,t} + 58,13D_{4,t} \\
 & + 19,34D_{5,t} - 20,28D_{6,t} + 0,58D_{7,t} - 28,51D_{8,t} \\
 & + 40,05D_{9,t} + 208,56D_{10,t} + 245,17D_{11,t} + 205,36D_{12,t} \quad (4.2) \\
 & + 0,14Z_{t-1} + 0,14Z_{t-2} + 0,13Z_{t-4} + 0,13Z_{t-12} + e_t.
 \end{aligned}$$



**Gambar 4.7** Plot ACF Residual Persamaan (4.2)

Dari Gambar 4.7 dapat dilihat residual telah memenuhi asumsi *white noise*. Namun untuk asumsi normalitasnya belum terpenuhi dimana nilai *skewness* dan *kurtosis* masing-masing bernilai 1,07 dan 2,60. Hal tersebut mengindikasikan distribusi dari residual menceng kanan dan berbentuk lancip. Penambahan input berupa variabel *lag* belum bisa mengatasi asumsi normalitas pada residual model, hanya bisa mengatasi masalah asumsi *white*

*noise*. Salah satu cara mengatasinya adalah perlu dilakukan deteksi *outlier*. Sehingga Model pada persamaan (4.2) bukan model yang terbaik. Setelah dilakukan deteksi *outlier* didapatkan sebanyak 14 data *outlier* seperti terlihat pada Tabel 4.6

**Tabel 4.6** Data Pengamatan *Outlier*

$t$	<i>Deleted residual</i>	$t$	<i>Deleted residual</i>
131	4,40	132	-2,68
118	3,89	105	2,58
106	3,79	249	2,52
82	3,58	130	-2,08
157	3,26	113	-2,07
156	2,87	109	2,07
192	2,87	87	-2,03

Setelah didapatkan pengamatan yang *outlier*, selanjutnya dimodelkan kembali sehingga memperoleh residual yang memenuhi asumsi normalitas. Dalam memodelkan dengan deteksi *outlier*, tidak semua *outlier* dimodelkan sekaligus dimana *outlier* yang memiliki nilai *deleted residual* paling besar yang dimodelkan terlebih dahulu.

$$\begin{aligned}
 Z_t = & 216,66D_{1,t} + 162,23D_{2,t} + 148,61D_{3,t} + 71,68D_{4,t} \\
 & + 41,89D_{5,t} - 14,18D_{6,t} + 6,54D_{7,t} - 25,87D_{8,t} \\
 & + 12,18D_{9,t} + 152,29D_{10,t} + 235,69D_{11,t} + 203,12D_{12,t} \\
 & + 0,14Z_{t-1} + 0,13Z_{t-2} + 0,13Z_{t-4} + 0,08Z_{t-12} \quad (4.3) \\
 & + 550,50I_{a,t}^{82} + 381,10I_{a,t}^{105} + 562,50I_{a,t}^{106} - 283,50I_{a,t}^{113} \\
 & + 602,90I_{a,t}^{118} - 175,10I_{a,t}^{130} + 618,90I_{a,t}^{131} - 324,20I_{a,t}^{132} \\
 & + 406I_{a,t}^{156} + 465,10I_{a,t}^{157} + 401,40I_{a,t}^{192} + 386,50I_{a,t}^{249} + e_t
 \end{aligned}$$

$$\text{dengan : } I_{a,t}^T = \begin{cases} 1, & t = T \\ 0, & t \neq T. \end{cases}$$

Setelah didapatkan model dengan deteksi *outlier* seperti pada persamaan (4.3), ternyata asumsi normalitas pada residual belum terpenuhi juga. Persamaan (4.3) tidak menginputkan semua *outlier* untuk mendapatkan nilai *skewness* dan *kurtosis* paling minimal, dimana masing-masing nilainya adalah sebesar 0,42 dan 0,1. Karena masih didapatkan hasil dimana residual tidak memenuhi asumsi normalitas, maka analisis akan dilanjutkan pada pengujian signifikansi parameternya. Meski tidak memenuhi asumsi normalitas, dapat dilihat nilai *skewness* dan *kurtosis* residual telah diminimalisir hingga mendekati nilai 0. Dimana distribusi normal memiliki nilai *skewness* dan *kurtosis* bernilai 0. Untuk menguji signifikan parameter, maka dilakukan pengujian individu seperti yang terlihat pada Tabel 4.7

**Tabel 4.7** Estimasi Parameter Persamaan (4.3)

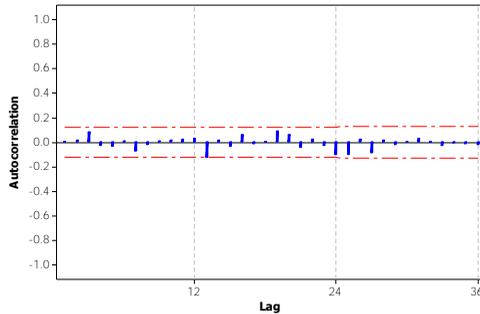
Parameter	Estimasi	SE	T	P
$\beta_1$	216,66	34,16	6,34	0,00
$\beta_2$	162,23	34,69	4,68	0,01
$\beta_3$	148,61	35,19	4,22	0,02
$\beta_4$	71,68	32,87	2,18	0,03
$\beta_5$	41,89	31,33	1,34	0,18
$\beta_6$	-14,18	28,43	-0,50	0,61
$\beta_7$	6,54	27,46	0,24	0,81
$\beta_8$	-25,87	24,98	-1,04	0,30
$\beta_9$	12,18	25,06	0,49	0,62
$\beta_{10}$	152,29	27,76	5,49	0,00
$\beta_{11}$	235,69	31,02	7,60	0,00
$\beta_{12}$	203,12	34,07	5,85	0,00
$Z_{t-1}$	0,14	0,05	2,84	0,00
$Z_{t-2}$	0,13	0,04	2,84	0,00
$Z_{t-4}$	0,13	0,04	2,91	0,00

**Tabel 4.7** (Lanjutan)

Parameter	Estimasi	SE	T	P
$Z_{t-12}$	0,08	0,04	1,65	0,10
ao 131	618,90	112,20	5,52	0,00
ao 118	602,90	115,10	5,24	0,00
ao 106	562,50	112,90	4,98	0,00
ao 82	550,50	111,30	4,94	0,00
ao 157	465,10	112,10	4,15	0,00
ao 156	460,00	112,00	3,63	0,00
ao 192	401,40	111,30	3,61	0,00
ao 132	-324,20	116,20	-2,79	0,00
ao 105	381,10	110,90	3,33	0,00
ao 249	386,50	111,40	3,47	0,00
ao 130	-175,10	115,70	-1,51	0,13
ao 113	-283,50	112,30	-2,52	0,01

Berdasarkan Tabel 4.7 terlihat cukup banyak parameter yang tidak signifikan. Dimana parameter dikatakan signifikan jika nilai  $P$  kurang dari 0,1. Karena cukup banyak parameter yang tidak signifikan dan asumsi normalitas belum terpenuhi, maka data curah hujan akan dimodelkan hingga semua parameternya bernilai signifikan. Adapun dalam pemodelan ditemukan 14 data *outlier*. Berikut adalah model yang didapatkan dengan melakukan deteksi *outlier* sekaligus.

$$\begin{aligned}
\cdot Z_t = & 207,48D_{1,t} + 131,68D_{2,t} + 118,42D_{3,t} + 134,81D_{10,t} \\
& + 217,21D_{11,t} + 198,38D_{12,t} + 0,17Z_{t-1} + 0,16Z_{t-2} \\
& + 0,14Z_{t-4} + 0,09Z_{t-12} + 558,40I_{a,t}^{82} + 562,10I_{a,t}^{106} \\
& + 602I_{a,t}^{118} + 621,70I_{a,t}^{131} + e_t.
\end{aligned} \tag{4.4}$$

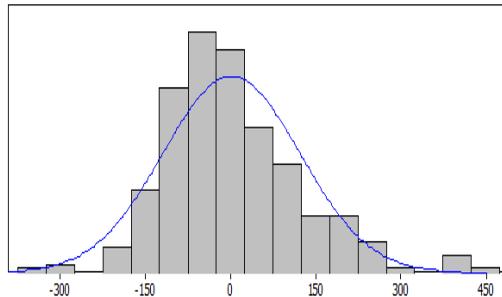


**Gambar 4.8** Plot ACF Residual Persamaan (4.4)

Pada persamaan (4.4) asumsi normalitas belum terpenuhi juga, namun semua parameternya sudah signifikan dan residual telah memenuhi asumsi *white noise* berdasarkan uji *Ljung-Box* dan *lagrange multiplier*. Selain itu pada persamaan (4.4) juga dilakukan deteksi *outlier* untuk mendapatkan nilai *skewness* dan *kurtosis* paling minimal, yaitu sebesar 0,71 dan 1,07. Penambahan *outlier* dapat mengakibatkan residual tidak memenuhi asumsi *white noise* ataupun identik meskipun mendapatkan nilai *skewness* dan *kurtosis* yang mendekati 0. Maka dalam persamaan (4.4) hanya mengikutkan 4 deteksi *outlier* untuk mendapatkan residual yang memenuhi asumsi *white noise* dan tetap meminimalkan nilai *skewness* dan *kurtosis*. Berikut adalah perubahan nilai *skewness* dan *kurtosis* serta distribusi residual persamaan (4.4).

**Tabel 4.8** Nilai *Skewness* dan *Kurtosis* Model Regresi *Time Series*

Model	<i>Skewness</i>	<i>Kurtosis</i>	RMSE <i>Out Sample</i>
Persamaan (4.1)	1,15	2,88	127,24
Persamaan (4.2)	1,07	2,60	131,25
Persamaan (4.3)	0,42	0,10	124,95
Persamaan (4.4)	0,71	1,07	118,24

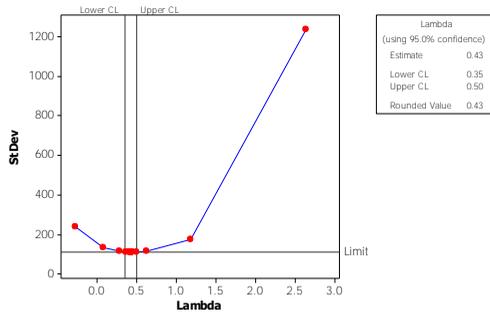


**Gambar 4.9** Distribusi Residual Persamaan (4.4)

Jadi, untuk metode regresi *time series* dapat dikatakan persamaan (4.4) merupakan model terbaik yang telah diperoleh. Dapat dilihat nilai ramalan waktu ke- $t$  dipengaruhi oleh beberapa data sebelumnya. Misalkan ramalan curah hujan bulan Januari tahun 2015 didapatkan berdasarkan nilai estimasi variabel *dummy* bulanannya. Selain itu juga berkaitan dengan curah hujan bulan Januari, September, November, dan Desember 2014. Hal tersebut juga berlaku untuk bulan Februari, Maret, Oktober, November dan Desember dimana curah hujan berkaitan dengan nilai estimasi variabel *dummy* bulanannya. Sedangkan untuk bulan lainnya curah hujan yang terjadi hanya berkaitan dengan satu bulan, dua bulan, empat bulan, dan duabelas bulan sebelumnya. Berdasarkan rumus pada persamaan (2.41) diperoleh nilai RMSE *out sample* dari model terbaik sebesar 118,24 mm.

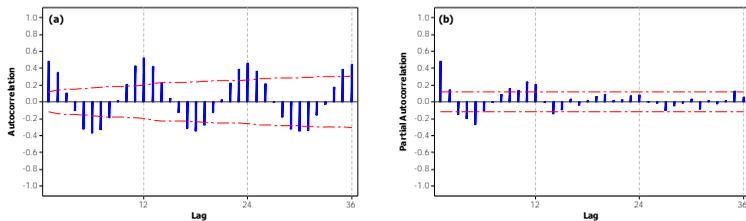
#### 4.3.2 Model ARIMA

Sebelum mendapatkan model ARIMA, data terlebih dahulu diuji apakah sudah memenuhi asumsi *stasioner*. Asumsi *stasioner* yang harus dipenuhi adalah *stasioner* dalam varians dan *mean*. Pertama akan diuji apakah data sudah *stasioner* dalam varians sebagai berikut



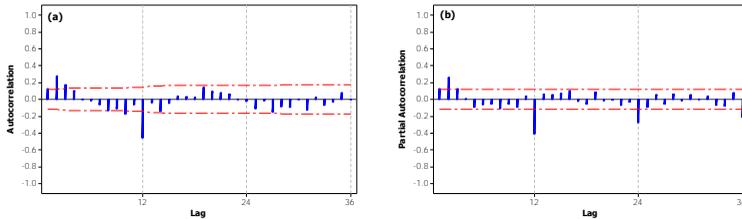
**Gambar 4.10** Uji Stasioner Data dalam Varians

Berdasarkan Gambar 4.10 diketahui bahwa data curah hujan belum *stasioner* dalam varians. Sehingga akan dilakukan transformasi sesuai nilai *lambda* yang didapatkan. Berdasarkan transformasi box-cox diperoleh nilai *lambda* sebesar 0,43. Setelah dilakukan transformasi didapatkan hasil bahwa data transformasi telah memenuhi *stasioner* dalam varians. Selanjutnya dilakukan pengujian *stasioner* dalam mean terhadap data yang sudah ditransformasi. Hasilnya menunjukkan bahwa perlu dilakukan *differencing* seperti yang terlihat pada Gambar 4.11.



**Gambar 4.11** Plot (a) ACF dan Plot (b) PACF

Berdasarkan Gambar 4.11 dapat dilihat plot ACF mengindikasikan adanya pola musiman dan perlu dilakukan *differencing* pada model musimannya. Berikut adalah plot ACF dan PACF dimana sudah dilakukan *differencing* 12.



**Gambar 4.12** Plot (a) ACF dan Plot (b) PACF Data Hasil Differencing 12

Berdasarkan Gambar 4.12, dapat ditentukan orde sementara dari model ARIMA. Terlihat plot ACF signifikan pada *lag-1*, *lag-2*, dan *lag-3*. Selain itu plot ACF juga mengindikasikan adanya orde pada model musimannya. Sedangkan pada plot PACF terlihat hal yang sama dengan plot ACF, namun pada plot PACF *lag-24* juga bernilai signifikan. Sehingga ada lebih dari satu kemungkinan model yang akan didapatkan. Berdasarkan plot ACF dan PACF mengindikasikan model yang didapatkan adalah *seasonal* ARIMA. Berikut adalah model ARIMA sementara yang telah diuji signifikan parameter serta asumsi residualnya.

**Tabel 4.9** Model ARIMA Intensitas Curah Hujan

Model	Model ARIMA	Asumsi Residual	Signifikansi Parameter
Model 1	$([2,3],0,0)(0,1,1)^{12}$	Terpenuhi	Terpenuhi
Model 2	$(2,0,0)(0,1,1)^{12}$	Terpenuhi	Terpenuhi
Model 3	$(1,0,1)(0,1,1)^{12}$	Terpenuhi	Terpenuhi
Model 4	$(1,0,2)(0,1,1)^{12}$	Terpenuhi	Terpenuhi
Model 5	$([2],0,2)(0,1,1)^{12}$	Terpenuhi	Terpenuhi

Setelah dilakukan analisis, hanya didapatkan lima model ARIMA yang memenuhi asumsi residual dan semua parameternya signifikan. Dari model 1 sampai model 5 diketahui model mengandung unsur musiman, sehingga dari model sementara yang didapatkan diketahui adanya keterkaitan bulan

dalam turunnya curah hujan. Untuk menentukan model terbaik diantara kelima model pada Tabel 4.9, akan dilihat nilai RMSE *out sample*. Perhitungan nilai RMSE sesuai rumus (2.41) didapatkan hasil sebagai berikut,

**Tabel 4.10** Nilai RMSE Model ARIMA

Model	Nilai RMSE <i>in sample</i>	Nilai RMSE <i>out sample</i>
Model 1	157,43	120,36
Model 2	157,27	118,41
Model 3	155,36	117,74
Model 4	156,32	119,99
Model 5	155,57	118,25

Berdasarkan Tabel 4.10, dapat dilihat nilai RMSE *out sample* kelima model. Terlihat Model 3 memiliki nilai RMSE yang paling kecil yaitu sebesar 117,74 sehingga model ARIMA terbaik adalah ARIMA (1,0,1)(0,1,1)<sup>12</sup>. Bentuk matematis Model 3 dapat dituliskan sebagai berikut

$$Z_t^* = 0,80Z_{t-1}^* + Z_{t-12}^* - 0,80Z_{t-13}^* - 0,64e_{t-1} - 0,73e_{t-12} + 0,46e_{t-13} + e_t. \quad (4.5)$$

Dari persamaan (4.5) dapat dilihat model terbaik dengan metode ARIMA. Model tersebut menjelaskan curah hujan pada bulan ke- $t$  berkaitan dengan curah hujan pada bulan sebelumnya, serta curah hujan 12 dan 13 bulan sebelumnya. Misalkan ingin dilihat nilai ramalan curah hujan bulan Januari tahun 2015, maka nilai ramalannya berkaitan dengan curah hujan bulan Januari tahun 2014. Selain itu curah hujan bulan Januari 2015 juga berkaitan dengan curah hujan bulan Desember tahun 2013 dan 2014. Begitu juga untuk bulan-bulan yang lain. Karena model tersebut menggunakan data curah hujan yang telah ditransformasi, sehingga untuk mendapatkan ramalannya perlu dilakukan transformasi data kembali.

### 4.3.3 Model RNN

Model RNN dibentuk dengan mengadaptasikan model Regresi *Time Series* dan ARIMA ke dalam bentuk nonlinier, oleh karena itu dilakukan pengujian nonlinier terlebih dahulu. Pada penelitian ini digunakan uji Terasvirta untuk mengetahui apakah data dalam hal ini curah hujan merupakan fungsi nonlinier dalam variabel input RNN.

**Tabel 4.11** Uji Nonlinieritas Terasvirta

Variabel input	$df_1$	$df_2$	$F$	$P$
Regresi <i>Time Series</i>	30	239	1,28	0,08
ARIMA	16	253	2,89	0,00

Berdasarkan Tabel 4.11, dapat dilihat nilai  $P$  kurang dari taraf signifikan sebesar 0,1 sehingga didapatkan kesimpulan model merupakan fungsi nonlinier. Dengan demikian, metode RNN dapat diterapkan dengan menggunakan hasil dari model regresi *time series* dan ARIMA. Banyaknya *layer* ditentukan sebanyak tiga, yang terdiri dari *input layer*, *hidden layer* dan *output layer*. Variabel yang digunakan pada *input layer* disesuaikan dengan variabel prediktor yang signifikan pada model regresi *time series* dan ARIMA terbaik. Banyaknya unit *neuron* pada *hidden layer* ditentukan dari nilai RMSE *outsample* terkecil, dengan mencoba menggunakan 1 sampai 10 unit. Banyaknya unit pada *output layer* adalah satu. Fungsi aktivasi yang digunakan pada *hidden layer* adalah fungsi *tangent sigmoid*, sedangkan pada *output layer* digunakan fungsi linier. Estimasi parameter dilakukan menggunakan metode *gradient descent* dengan momentum, dengan iterasi maksimal 1000, atau sampai diperoleh selisih MSE 0,001, atau sampai diperoleh *gradient* kurang dari  $10^{-7}$ .

#### 4.3.3.1 Model RNN Berdasarkan Model Regresi *Time Series* Terbaik.

Berdasarkan model regresi *time series* terbaik pada persamaan (4.4) maka input yang digunakan pada model RNN adalah semua variabel yang signifikan yaitu sebanyak 14 variabel

yang terdiri dari  $D_{1,t}$ ,  $D_{2,t}$ ,  $D_{3,t}$ ,  $D_{10,t}$ ,  $D_{11,t}$ ,  $D_{12,t}$ ,  $Z_{t-1}$ ,  $Z_{t-2}$ ,  $Z_{t-4}$ ,  $Z_{t-12}$ ,  $I_{a,t}^{82}$ ,  $I_{a,t}^{106}$ ,  $I_{a,t}^{118}$ ,  $I_{a,t}^{131}$ . Berikut adalah nilai RMSE dari model yang menggunakan 1 sampai 10 unit di *hidden layer*.

**Tabel 4.12** RMSE Model RNN input Regresi *Time Series*

Jumlah unit di <i>hidden layer</i>	RMSE <i>in sample</i>	RMSE <i>out sample</i>
1	131,21	<b>124,53</b>
2	114,78	130,68
3	111,39	125,22
4	99,22	144,60
5	95,55	161,19
6	89,52	153,32
7	78,45	196,93
8	80,11	165,75
9	66,99	295,52
10	40,08	182,10

Dari Tabel 4.12 dapat diketahui bahwa RMSE *out sample* terkecil dihasilkan oleh model dengan 1 unit pada *hidden layer*. Jadi model RNN terbaik untuk peramalan intensitas curah hujan adalah Jordan-RNN (14,1,1). Artinya model tersebut menggunakan 14 variabel sebagai input, 1 unit pada *hidden layer* dan 1 unit pada *output layer*. Bentuk matematis model Jordan-RNN (14,1,1) dapat ditulis sebagai berikut.

$$Z_t = -0,08 - 0,89 f^h(X_{1,t}) + e_t \quad (4.6)$$

dengan

$$f^h(X_{1,t}) = \frac{2}{1 + e^{-2X_{1,t}}} - 1$$

$$\begin{aligned}
X_{1,t} = & -7,19 - 0,33D_{1,t} - 0,22D_{2,t} - 0,21D_{3,t} - 0,21D_{10,t} - 0,34D_{11,t} \\
& - 0,32D_{12,t} - 0,24Z_{t-1} - 0,17Z_{t-2} - 0,19Z_{t-4} - 0,14Z_{t-12} \\
& + 11,37I_{a,t}^{82} - 0,99I_{a,t}^{106} - 0,87I_{a,t}^{118} - 8,53I_{a,t}^{131} - 0,62Z_{t-1}^*
\end{aligned}$$

#### 4.3.3.2 Model RNN Berdasarkan Model ARIMA Terbaik.

Berdasarkan model ARIMA pada persamaan (4.5) maka input yang digunakan pada model RNN adalah semua variabel yang signifikan yaitu sebanyak 3 variabel yang terdiri dari  $Z_{t-1}$ ,  $Z_{t-12}$ ,  $Z_{t-13}$ . Berikut adalah nilai RMSE dari model yang menggunakan 1 sampai 10 unit di *hidden layer*.

**Tabel 4.13** RMSE Model RNN input ARIMA

Jumlah unit di <i>hidden layer</i>	RMSE <i>in sample</i>	RMSE <i>out sample</i>
1	150,96	148,19
2	143,37	145,31
3	141,17	144,44
4	138,97	<b>141,73</b>
5	130,42	187,44
6	132,53	157,21
7	126,74	171,28
8	123,46	203,77
9	119,71	240,03
10	118,96	187,81

Dari Tabel 4.13 dapat diketahui bahwa RMSE *out sample* terkecil dihasilkan oleh model dengan 4 unit pada *hidden layer*. Jadi model RNN terbaik untuk peramalan intensitas curah hujan adalah Jordan-RNN (3,4,1). Artinya model tersebut menggunakan 3 variabel sebagai input, 4 unit pada *hidden layer* dan 1 unit pada

*output layer*. Bentuk matematis model Jordan-RNN (3,4,1) dapat ditulis sebagai berikut.

$$Z_t = -71,05 - 102,57f^h(X_{1,t}) + 59,13f^h(X_{2,t}) - 171,09f^h(X_{3,t}) - 61,95f^h(X_{4,t}) + e_t \quad (4.7)$$

dengan

$$f^h(X_{j,t}) = \frac{2}{1 + e^{-2X_{j,t}}} - 1, \text{ dimana } j=1,2,3,4$$

$$X_{1,t} = 2,18 + 0,55Z_{t-1} + 1,02Z_{t-2} - 0,58Z_{t-3} - 0,02Z_{t-1}^*$$

$$X_{2,t} = -3,94 - 2,65Z_{t-1} + 2,53Z_{t-2} + 0,22Z_{t-3} + 1,18Z_{t-1}^*$$

$$X_{3,t} = -2,35 - 0,51Z_{t-1} - 0,94Z_{t-2} + 0,52Z_{t-3} + 0,88Z_{t-1}^*$$

$$X_{4,t} = -3,85 - 2,55Z_{t-1} + 12,43Z_{t-2} + 0,18Z_{t-3} - 1,46Z_{t-1}^*.$$

Dimana nilai  $Z_{t-1}^*$  adalah nilai ramalan untuk  $Z_t$  pada iterasi ke  $k-1$  dengan  $k$  adalah total jumlah iterasi.

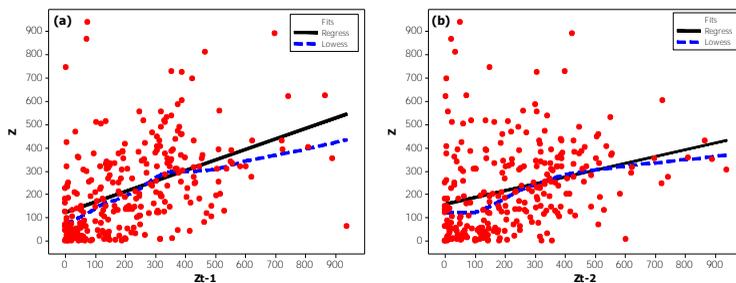
#### 4.4 Perbandingan Model Regresi *Time Series*, ARIMA, dan RNN

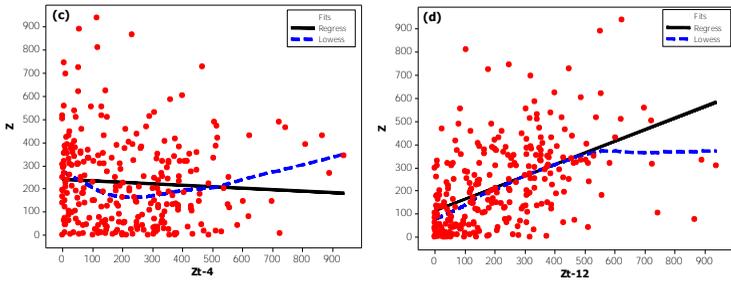
Pada tahap ini akan ditentukan model terbaik diantara ketiga metode yang digunakan. Model yang dibandingkan adalah model regresi *time series* terbaik, ARIMA terbaik dan model RNN terbaik untuk masing-masing variabel berdasarkan kriteria RMSE. Sehingga akan ada empat model yang dibandingkan. Pemilihan model terbaik berdasarkan nilai *out sample* terkecil Berikut ditampilkan perbandingan kriteria *out sample* keempat model tersebut.

**Tabel 4.14** RMSE Model Regresi *Time Series*, ARIMA, dan RNN

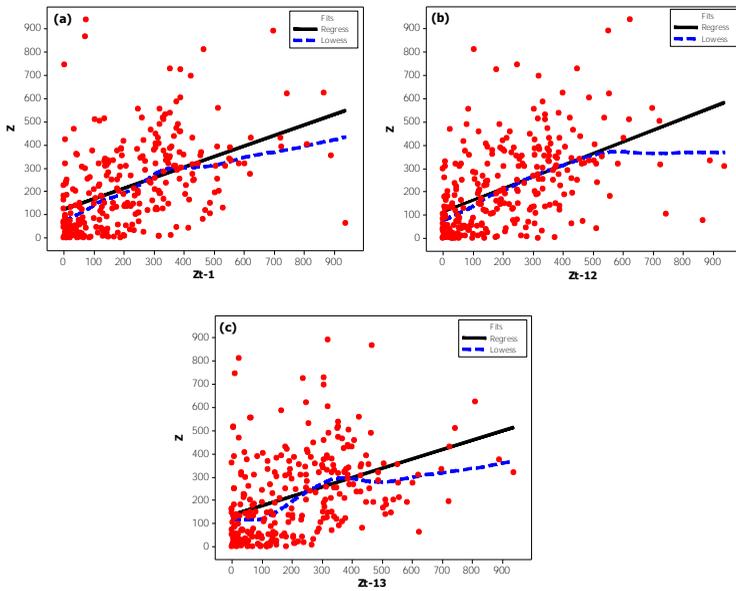
Model	RMSE <i>in sample</i>	RMSE <i>out sample</i>
Regresi <i>Time Series</i>	121,19	118,24
ARIMA	155,36	<b>117,74</b>
RNN-TSR	131,21	124,53
RNN-ARIMA	138,97	141,73

Dari Tabel 4.14 dapat dilihat berdasarkan kriteria *out sample*, model ARIMA menghasilkan nilai RMSE yang lebih kecil dibandingkan model regresi *time series* ataupun RNN. Model ARIMA yang didapatkan dapat mereduksi standar deviasi data sebesar 36,57%. Namun model regresi *time series* masih bisa dipertimbangkan mengingat nilai RMSE *in sample* yang diperoleh lebih kecil, dan nilai RMSE *out sample* yang diperoleh tidak terlalu berbeda jauh dengan metode ARIMA. Dari analisis yang telah dilakukan, didapatkan kesimpulan model yang lebih kompleks tidak selalu menghasilkan model ramalan yang lebih baik. Hasil yang sama juga didapatkan pada penelitian tentang peramalan jumlah penumpang pesawat oleh Suhartono (2005). Selain itu, model RNN yang berbasis nonlinier lebih efektif digunakan untuk data yang bersifat nonlinier. Meskipun hasil pengujian Terasvirta mendapatkan kesimpulan nonlinier, namun jika dilihat hubungan curah hujan dengan masing-masing variabel inputnya cenderung memiliki hubungan linier seperti yang terlihat pada Gambar 4.13 dan Gambar 4.14.



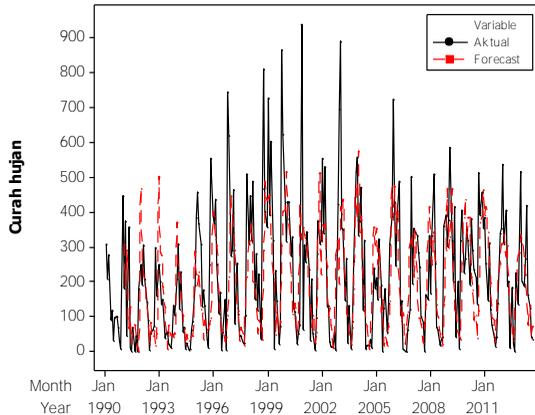


**Gambar 4.13** Scatterplot  $Z$  dengan (a)  $Z_{t-1}$ , (b)  $Z_{t-2}$ , (c)  $Z_{t-4}$ , dan (d)  $Z_{t-12}$  untuk Model Regresi Time Series

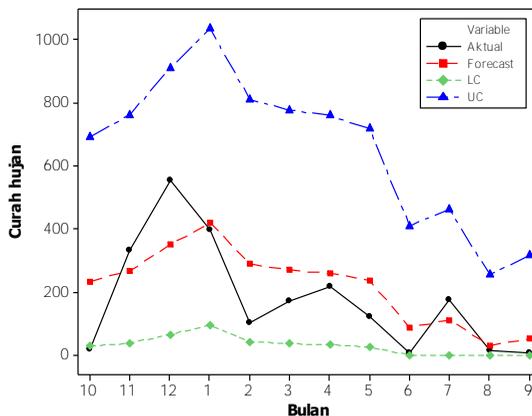


**Gambar 4.14** Scatterplot  $Z$  dengan (a)  $Z_{t-1}$ , (b)  $Z_{t-12}$ , dan (c)  $Z_{t-13}$ , untuk Model ARIMA

Berdasarkan Gambar 4.13 dan Gambar 4.14 terlihat untuk masing-masing variabel inputnya,  $Z$  atau curah hujan dalam hal ini cenderung memiliki hubungan yang linier. Sehingga metode RNN tidak memberikan hasil ramalan yang baik. Berikut adalah hasil ramalan *in sample*, *out sample*, dan ramalan curah hujan untuk 12 periode kedepan dengan metode ARIMA.



**Gambar 4.15** Ramalan *In Sample* Metode ARIMA



**Gambar 4.16** Ramalan *Out Sample* Metode ARIMA

**Tabel 4.15** Ramalan Curah Hujan dengan Metode ARIMA

Tahun	Bulan Masehi	Sasih	Ramalan curah hujan
2014	Oktober	<i>Kapat</i>	115,10
	November	<i>Kalima</i>	242,33
	Desember	<i>Kanem</i>	356,53
2015	Januari	<i>Kapitu</i>	378,94
	Februari	<i>Kawulu</i>	208,82
	Maret	<i>Kasanga</i>	223,96
	April	<i>Kadasa</i>	233,97
	Mei	<i>Desta</i>	191,67
	Juni	<i>Sada</i>	51,69
	Juli	<i>Kasa</i>	121,82
	Agustus	<i>Karo</i>	24,47
	September	<i>Katiga</i>	32,58

#### 4.5 Penyesuaian Pola Pertanian Berdasarkan Penanggalan Sasih dengan Prediksi Curah Hujan yang Terjadi

Pada tahap ini akan dilihat kesesuaian pola pertanian berdasarkan penanggalan sasih jika dikaitkan dengan prediksi curah hujan yang terjadi. Untuk memudahkan analisis, prediksi curah hujan dikategorikan berdasarkan kategori curah hujan dari BMKG sebagai berikut.

**Tabel 4.16** Kategori Curah Hujan Berdasarkan Hasil Ramalan ARIMA

Tahun	2014			2015								
Sasih	4	5	6	7	8	9	10	11	12	1	1	3
Masehi	10	11	12	1	2	3	4	5	6	7	8	9
Curah hujan												

keterangan :

0-20 mm		101-150 mm		301-400 mm	
21-50 mm		151-200 mm		401-500 mm	
51-100 mm		201-300 mm		>500 mm	

Berdasarkan Tabel 4.16, dapat dilihat penanggalan *sasih* untuk kedepannya masih relevan digunakan untuk penentuan pola tanam. Hal tersebut dapat dilihat pada *sasih kapitu* atau bulan Januari, didapatkan nilai ramalan curah hujan yang termasuk dalam kategori tinggi. Sehingga pola pertanian berdasarkan penanggalan *sasih* masih dapat diterapkan. Namun ada baiknya tetap dilakukan evaluasi tiap tahun untuk melihat tingkat ketepatan penanggalan *sasih*. Sehingga dinas atau badan terkait dalam hal ini *Subak* dan Dinas Pertanian dapat melakukan antisipasi jika terjadi kesalahan dengan prediksi curah hujan.

“Halaman ini sengaja dikosongkan”

## **BAB V**

### **KESIMPULAN DAN SARAN**

#### **5.1 Kesimpulan**

Dari hasil analisis dan pembahasan yang telah dilakukan diperoleh kesimpulan sebagai berikut.

1. Hasil analisis deskriptif menunjukkan bahwa curah hujan di daerah Jatiluwih memiliki pola musiman, dimana curah hujan cenderung tinggi mulai bulan Oktober dan mengalami penurunan mulai bulan Maret. Selama 25 tahun dari tahun 1990-2014 intensitas curah hujan cukup stabil meski pada tahun-tahun tertentu ada beberapa pengamatan yang *outlier*.
2. Berdasarkan curah hujan yang terjadi selama 25 tahun, pola tanam berdasarkan penanggalan *sasih* hanya kurang sesuai sebanyak empat kali. Jika diproporsikan sebesar 87,50%. Selain itu tercatat curah hujan kategori tinggi paling banyak terjadi pada *sasih kapitu*, dimana hal tersebut memberikan dampak positif pada hasil panen. Sehingga penanggalan *sasih* masih relevan digunakan jika dikaitkan dengan kondisi curah hujan yang terjadi.
3. Berdasarkan analisis yang telah dilakukan diperoleh bahwa model ARIMA  $(1,0,1)(0,1,1)^{12}$  merupakan model terbaik untuk peramalan curah hujan pada penelitian ini.
4. Setelah dilakukan peramalan sebanyak 12 bulan kedepan, dapat disimpulkan bahwa pola tanam berdasarkan penanggalan *sasih* masih sesuai jika dikaitkan dengan prediksi curah hujan.

#### **5.2 Saran**

Beberapa saran yang dianjurkan untuk penelitian selanjutnya adalah sebagai berikut.

1. Untuk peramalan curah hujan, sebaiknya melihat faktor-faktor lain seperti suhu, kelembapan udara, kecepatan angin, dan lain-lain. Sehingga diharapkan mendapatkan hasil ramalan yang lebih akurat.

2. Perlu dilakukan pengembangan program RNN agar dapat melakukan peramalan yang melebihi order AR sehingga semua parameter signifikan bisa menjadi input dari model RNN.
3. Sebaiknya tetap dilakukan evaluasi setiap tahun terhadap fungsi penanggalan *sasih* di bidang pertanian. Tidak hanya melihat dari kondisi curah hujan, namun faktor-faktor berpengaruh lainnya juga.
4. Pada dasarnya, model *time series* baik digunakan untuk peramalan jangka pendek, sehingga untuk mendapatkan ramalan yang lebih akurat, *subak* atau dinas terkait sebaiknya menggunakan data curah hujan yang terbaru. Selain itu perlu adanya kerja sama antara BMKG, Dinas Pertanian, dan *subak* dalam penentuan kalender tanam. Sehingga setiap tahunnya bisa dilakukan evaluasi terhadap pola pertanian di Bali.

## DAFTAR PUSTAKA

- Babad Bali. 2010. *Kalender Saka Bali*. Diakses 7 Maret 2015, dari <http://www.babadbali.com/pewarigaan/kalender-saka.htm>.
- Balkin, S. D. 1997. *Using recurrent neural networks for time series forecasting*. Pennsylvania State University.
- Bone, R., & Cardot, H. 2011. Advanced methods for time series prediction using recurrent neural networks. *Recurrent Neural Networks for Temporal Data Processing*, 15-36.
- Bowerman, B. L., & O'Connell, R. T. 1993. *Forecasting and Time Series: An Applied Approach*, Third Edition. California: Duxbury Press.
- Chong, E. K., & Zak, S. H. 2001. *An introduction to optimization* (2nd ed.). USA: John Wiley & Sons.
- Cryer, J. D., & Chan, K. S. 2008. *Time Series Analysis With Application in R*, 2nd Edition. New York: Springer.
- Daniel, W. W. 2005. *Biostatistics A Foundation for Analysis in the Health Sciences*, Eighth Edition. United States of America: John Wiley & Sons, Inc.
- Destra, W. P. 2013. *Aplikasi Sistem Kalender Bali Berbasis Mobile Application Pada Blackberry Platform*. Vol. 1, No. 1.
- Diani, K. A. N., Setiawan, & Suhartono. 2013. *Pemodelan VAR-NN dan GSTAR-NN untuk Peramalan Curah Hujan di Kabupaten Malang*. *Jurnal Sains dan Seni ITS*, 2(1), D31-D36.
- Enders, W. 2015. *Applied Econometric Time Series, Fourth Edition*. University of Alabama.
- Greertz, C. 1980. *Organization of The Balinese Subak*. Itacha : Cornell University.

- Huda, A. M., Choiruddin, A., Budiarto, O., & Sutikno. 2012. *Peramalan Data Curah Hujan dengan Seasonal Autoregressive Integrated Moving Average (SARIMA) dengan Deteksi Outlier sebagai Upaya Optimalisasi Produksi Pertanian di Kabupaten Mojokerto*. Surabaya : Institut Teknologi Sepuluh Nopember Surabaya.
- Kecamatan Penebel. 2013. *Desa Jatiluwih*. Diakses 8 November 2014, dari <http://penebel.tabanankab.go.id/desa-jatiluwih/>.
- Mangostina, C. 2010. *Curah Hujan*. Diakses 10 Januari 2015, dari <http://bidinagtuns.blogspot.com/2010/11/curah-hujan.html>.
- Mirawati, T. D., Yasin, H., & Rusgiyono, A. 2013. *Prediksi Curah Hujan dengan Metode Kalman Filter (Studi Kasus di Kota Semarang)*. *Jurnal Gaussian*, 2(3), 239-248.
- Perdana, A. S. 2010. *Perbandingan Metode Time Series Regression dan ARIMAX Pada Pemodelan Data Penjualan Pakaian di Boyolali*. Surabaya : Institut Teknologi Sepuluh Nopember Surabaya.
- Picard, M. 1992. *Bali:Pariwisata Budaya dan Budaya Pariwisata*. Indonesia: KPG.
- Pitana, I Gde. 1993. *SUBAK, Sistem Irigasi Tradisional di Bali (Sebuah Canangsari)*. Bali : PT. Upada Sastra.
- Purnomo. 2011. *Dampak Perubahan Iklim untuk Pertumbuhan Tanaman*. Diakses 10 Januari 2015, dari <http://www.slideshare.net/pramana2000/dampak-perubahan-iklim-thdp-tanaman>.
- Ratag, M. 2007. *Perubahan iklim: Perubahan variasi curah hujan, cuaca dan iklim ekstrim*. Badan Metereologi dan Geofisika, Jakarta.

- Shumway, R. H., & Stoffer, D. S. 2006. *Time Series Analysis and Its Applications with R Examples* (2nd ed.). Berlin: Springer.
- Suhartono. 2005. *A Comparative Study Of Forecasting Models For Trend And Seasonal Time Series: Does Complex Model Always Yield Better Forecast Than Simple Models?.* *Jurnal Teknik Industri*, 7(1), 22-30.
- Suhartono & Endharta A. J. 2009. *Peramalan Konsumsi Listrik Jangka Pendek dengan ARIMA Musiman Ganda dan Elman-Recurrent Neural Network.* *Jurnal Ilmiah Teknologi Informasi*, 7(4), 183-190
- Terasvirta, T., Lin, C., & Granger, C. W. J. 1993. *Power of The Neural Network Linearity Test.* *Jurnal of Time Series Analysis*, 14(2), 209-220.
- Wahyudi, R. 2013. *Pengertian dan Macam-Macam Pola Tanam.* Diakses 10 Januari 2015, dari <http://mentari-dunia.blogspot.com/2013/01/pengertian-pola-tanam-dan-macam-macam.html>.
- Walpole, R. E., & Myers, H. 2010. *Ilmu Peluang dan Statistika untuk Insinyur dan Ilmuwan Edisi ke-4.* Bandung: ITB.
- Warsito, B., Tarno, & Sugiharto, A. 2008. *Prediksi Curah Hujan sebagai Dasar Perencanaan Pola Tanam Padi dan Palawija Menggunakan Model General Regression Neural Network.* *Jurnal Ilmiah*, Vol.2 No. 3 UNDIP
- Wei, W. W. S. 2006. *Time Series Analysis: Univariate and Multivariate Methods*, 2nd Edition. New York: Pearson.
- Widosari, G. 2011. *Peramalan Curah Hujan dengan Metode Wavelet.* ISBN : 978-979-16353-8-7, MT61-MT68.

“Halaman ini sengaja dikosongkan”

## LAMPIRAN

### Lampiran A. Data Curah Hujan di Desa Jatiluwih

#### A1. Data *in sample*

Tahun	Bulan	t	Curah Hujan
1990	Januari	1	307
1990	Februari	2	206
1990	Maret	3	278
⋮	⋮	⋮	⋮
2000	Desember	132	62
2001	Januari	133	303
2001	Februari	134	256
⋮	⋮	⋮	⋮
2013	Agustus	284	40
2013	September	285	34

#### A2. Data *out sample*

Tahun	Bulan	t	Curah Hujan
2013	Oktober	286	19
2013	November	287	333
2013	Desember	288	555
⋮	⋮	⋮	⋮
2014	Agustus	296	15
2014	September	297	5

**Lampiran B.** Program SAS untuk Pemodelan ARIMA

Pemodelan ARIMA (1,0,1)(0,1,1)<sup>12</sup> untuk data intensitas curah hujan.

```
data hujan;
input y;
datalines;
11,75105362
9,905291221
11,26185179
6,923477403
7,750325108
4,4973946
7,11830562
:
2,308831065
9,282834358
3,294364069
2,160752567
;
proc arima data=hujan;
identify var=y(12);
estimate p=(1)(0) q=(1)(12) noconstant method=cls;
forecast out=ramalan lead=12;
run;
proc univariate data=ramalan normal;
var residual;
run;

proc export data=work.ramalan
outfile='D:\ramalan.xls'
dbms=excel
replace;
run;
```

## Lampiran C. Program Matlab untuk peramalan RNN

### C1. Pemodelan Jordan-RNN (14,1,1) untuk data intensitas curah hujan input Regresi *Time Series*

```

clear; clc;

% Data input & target
data=load('D:\data1.txt');
m=273;
P=[data(1:m,2:15)];
T=data(1:m,1);
n=length(T);
TQ=data(m+1:m+12);
n1=length(TQ);

% Preprocessing
[pn,minp,maxp,tn,mint,maxt]=premnmx(P,T);

% Membangun Jordan neural network
net=newjor(minmax(pn),[1 1],{'tansig' 'purelin'},'trainlm');
net=init(net);

% Melihat bobot-bobot awal input, lapisan, dan bias
bobotawal_input=net.IW{1,1};
bobotawal_bias_input=net.b{1,1};
bobotawal_lapisan1=net.LW{2,1};
bobotawal_bias_lapisan1=net.b{2,1};

% Set max epoh, goal, learning rate, show step
net.trainParam.epochs=1000;
net.trainParam.goal=1e-3;

% Melakukan pembelajaran
net=train(net,pn,tn);

```

**Lampiran C. (Lanjutan)**

## C1. (Lanjutan)

```

% Melihat bobot-bobot akhir input, lapisan, dan bias
bobotakhir_input=net.IW{1,1};
bobotakhir_bias_input=net.b{1,1};
bobotakhir_lapisan1=net.LW{2,1};
bobotakhir_bias_lapisan1=net.b{2,1};
wb = formwb(net,net.b,net.IW,net.LW);

% Melakukan simulasi
an=sim(net,pn);
a=postmnmx(an,mint,maxt);
residual_in=T'-a';
H1=[(1:size(P,2))' T' a' (T'-a)'];
sprintf('%2d%9.4f%9.4f%9.4f\n',H1);

% Perhitungan kriteria in-sampel dan out-sampel
mse_in=(residual_in)'*(residual_in)/n;
rmse_in=sqrt(mse_in)

% Peramalan
q=[data(m+1:m+12,2:15)]';
yn=trammx(q,minp,maxp);
ybn=sim(net,yn);
y=postmnmx(ybn,mint,maxt);
forecast=y'

residual_out=TQ'-forecast;
mse_out=(residual_out)'*(residual_out)/n1;
rmse_out=sqrt(mse_out)

```

### Lampiran C. (Lanjutan)

#### C2. Pemodelan Jordan-RNN (3,4,1) untuk data intensitas curah hujan input ARIMA

```

lear; clc;

% Data input & target
data=load('D:\data2.txt');
m=272;
P=[data(1:m,2:4)];
T=data(1:m,1);
n=length(T);
TQ=data(m+1:m+12);
n1=length(TQ);

% Preprocessing
[pn,minp,maxp,tn,mint,maxt]=premnmx(P,T);

% Membangun Jordan neural network
net=newjor(minmax(pn),[4 1],{'tansig' 'purelin'},'trainlm');
net=init(net);

% Melihat bobot-bobot awal input, lapisan, dan bias
bobotawal_input=net.IW{1,1};
bobotawal_bias_input=net.b{1,1};
bobotawal_lapisan1=net.LW{2,1};
bobotawal_bias_lapisan1=net.b{2,1};

% Set max epoh, goal, learning rate, show step
net.trainParam.epochs=1000;
net.trainParam.goal=1e-3;

% Melakukan pembelajaran
net=train(net,pn,tn);

```

**Lampiran C.** (Lanjutan)

## C2. (Lanjutan)

```

% Melihat bobot-bobot akhir input, lapisan, dan bias
bobotakhir_input=net.IW{1,1};
bobotakhir_bias_input=net.b{1,1};
bobotakhir_lapisan1=net.LW{2,1};
bobotakhir_bias_lapisan1=net.b{2,1};
wb = formwb(net,net.b,net.IW,net.LW);

% Melakukan simulasi
an=sim(net,pn);
a=postmnmx(an,mint,maxt);
residual_in=T'-a';
H1=[(1:size(P,2))' T' a' (T'-a)'];
sprintf('%2d%9.4f%9.4f%9.4f\n',H1);

% Perhitungan kriteria in-sampel dan out-sampel
mse_in=(residual_in)'*(residual_in)/n;
rmse_in=sqrt(mse_in)

% Peramalan
q=[data(m+1:m+12,2:4)];
yn=tramnmx(q,minp,maxp);
ybn=sim(net,yn);
y=postmnmx(ybn,mint,maxt);
forecast=y'

residual_out=TQ'-forecast;
mse_out=(residual_out)'*(residual_out)/n1;
rmse_out=sqrt(mse_out)

```

## Lampiran D. Regresi *Time Series*

### D1. Estimasi model regresi *time series*

#### Regression Analysis: Y versus D1, D2, ...

The regression equation is

$$Y = 207 D1 + 132 D2 + 118 D3 + 135 D10 + 217 D11 + 198 D12 + 0.174 Y_{t-1} + 0.169 Y_{t-2} + 0.140 Y_{t-4} + 0.0997 Y_{t-12} + 622 ao131 + 562 ao106 + 602 ao118 + 558 ao82$$

273 cases used, 12 cases contain missing values

Predictor	Coef	SE Coef	T	P
Noconstant				
D1	207.48	33.97	6.11	0.000
D2	131.68	31.74	4.15	0.000
D3	118.42	30.99	3.82	0.000
D10	134.81	30.90	4.36	0.000
D11	217.21	32.66	6.65	0.000
D12	198.38	34.52	5.75	0.000
Yt-1	0.17417	0.05235	3.33	0.001
Yt-2	0.16931	0.04986	3.40	0.001
Yt-4	0.14017	0.04173	3.36	0.001
Yt-12	0.09972	0.05255	1.90	0.059
ao131	621.7	129.0	4.82	0.000
ao106	562.1	129.7	4.34	0.000
ao118	602.0	131.0	4.60	0.000
ao82	558.4	128.0	4.36	0.000

S = 124.431

#### Analysis of Variance

Source	DF	SS	MS	F	P
Regression	14	19357388	1382671	89.30	0.000
Residual Error	259	4010088	15483		
Total	273	23367476			

**Lampiran D.** (Lanjutan)*D2. Lagrange multiplier test*

$Q^*$	$df$	$P$
1.6104	1	0.2044
1.6891	2	0.4297
2.4429	3	0.4856
3.6688	4	0.4526
4.1803	5	0.5237
4.3166	6	0.6339
4.5443	7	0.7153
5.2542	8	0.7300
6.2517	9	0.7144
6.6047	10	0.7621
7.4185	11	0.7642
9.8737	12	0.6270

## Lampiran E. Model ARIMA

Parameter	Standard		Approx		Lag
	Estimate	Error	t Value	Pr >  t	
MA1,1	0.64839	0.14187	4.57	<.0001	1
MA2,1	0.73531	0.04228	17.39	<.0001	12
AR1,1	0.80575	0.11053	7.29	<.0001	1

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	5.05	3	0.1678	-0.066	0.000	0.043	0.048	-0.054	-0.020
12	7.87	9	0.5473	-0.017	-0.046	-0.019	-0.076	0.033	0.011
18	11.00	15	0.6942	0.001	-0.063	-0.031	0.091	-0.005	0.017
24	19.01	21	0.5847	0.114	0.083	0.030	-0.015	0.056	-0.015
30	23.38	27	0.6645	-0.054	0.006	-0.095	-0.005	-0.026	0.040
36	29.34	33	0.6502	-0.036	0.049	-0.056	-0.072	0.080	-0.021
42	41.37	39	0.3676	0.110	0.020	0.122	0.014	0.097	-0.026
48	48.55	45	0.3319	0.051	-0.099	0.006	-0.057	-0.041	0.066

### Tests for Normality

Test	--Statistic--	-----p Value-----
Shapiro-Wilk	W 0.99085	Pr < W 0.0862
Kolmogorov-Smirnov	D 0.045958	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.112824	Pr > W-Sq 0.0795
Anderson-Darling	A-Sq 0.779904	Pr > A-Sq 0.0438

### Q Tests for ARCH Disturbances

Order	Q	Pr > Q
1	2.8954	0.0888
2	3.3482	0.1875
3	4.3085	0.2300
4	4.9008	0.2976
5	4.9868	0.4175
6	5.3067	0.5051
7	5.6245	0.5842
8	5.6825	0.6827
9	7.8010	0.5543
10	12.0232	0.2835
11	12.7416	0.3105
12	13.5722	0.3289

## Lampiran F. Model RNN

### F1. Model RNN input Regresi *Time Series*

Bobot *hidden layer* ke *output layer* model RNN  
input Regresi *Time Series*

Hidden	Output
Bias	-0,08
1	-0,89

Bobot *input layer* ke *hidden layer* model RNN  
input Regresi *Time Series*

Input	Hidden 1
Bias	-7,19
$D_{1,t}$	-0,33
$D_{2,t}$	-0,22
$D_{3,t}$	-0,21
$D_{10,t}$	-0,21
$D_{11,t}$	-0,34
$D_{12,t}$	-0,32
$Z_{t-1}$	-0,24
$Z_{t-2}$	-0,17
$Z_{t-4}$	-0,19
$Z_{t-12}$	-0,14
$I_{a,t}^{131}$	-8,53
$I_{a,t}^{118}$	-7,87
$I_{a,t}^{106}$	-0,99
$I_{a,t}^{82}$	11,37
<i>Context unit</i>	-0,62

**Lampiran F.** (Lanjutan)

## F2. Model RNN input ARIMA

Bobot *hidden layer* ke *output layer* model RNN  
Input ARIMA

Hidden	Output
Bias	-71,05
1	-102,57
2	59,13
3	-171,09
4	-61,95

Bobot *input layer* ke *hidden layer* model RNN  
Input ARIMA

Input	Hidden 1	Hidden 2	Hidden 3	Hidden 4
Bias	2,18	-3,94	-2,35	-3,85
$Z_{t-1}$	0,55	-2,65	-0,51	-2,55
$Z_{t-12}$	1,02	2,53	-0,94	2,43
$Z_{t-13}$	-0,58	0,22	0,52	0,18
<i>Context unit</i>	-0,02	1,18	0,88	-1,46

### Lampiran G. Contoh Perhitungan Manual Uji Terasvirta dengan Satu Variabel Prediktor

x	y
0.19122	2.00000
0.24089	4.00000
0.14811	4.00000
0.22706	0.68117
0.41829	5.00000
1.91675	3.00000
1.88229	2.00000
0.65326	1.00000
0.39333	3.00000
0.28915	0.86746

$$\begin{aligned}
 F &= \frac{(SSR_0 - SSR) / m}{SSR / (N - r - m - 1)} \\
 &= \frac{(19.891 - 18.151) / 2}{18.151 / 6} \\
 &= 0.2875
 \end{aligned}$$

#### Regression Analysis: y versus x

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	1	0.052	0.052	0.02	0.889
Residual Error	8	19.891	2.486		
Total	9	19.943			

#### Regression Analysis: RES1 versus x, x^2, x^3

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	3	1.740	0.580	0.19	0.898
Residual Error	6	18.151	3.025		
Total	9	19.891			

## BIODATA PENULIS



Penulis memiliki nama lengkap I Made Adi Purwaputra, lahir di Denpasar, 20 Agustus 1993 sebagai anak kedua dari pasangan I Nyoman Diasa dan Ni Wayan Agustini. Penulis memiliki dua saudara perempuan yaitu Ni Wayan Mey Diantini dan Ni Nyoman Sintha Aprilia. Penulis telah menempuh pendidikan formal di TK Swa Dharma tahun 1998-1999, SD Negeri 1 Peguyangan tahun 1999-2005, SMP Negeri 10 Denpasar tahun 2005-2008 dan SMA Negeri 3 Denpasar tahun 2008-2011. Pada tahun 2011 penulis diterima di program studi S-1 Statistika Institut Teknologi Sepuluh Nopember dan terdaftar dengan NRP 1311100125. Selama masa kuliah penulis aktif dalam kegiatan organisasi, diantaranya sebagai staf PSDM TPKH ITS pada tahun 2012-2013, sebagai staf PR PSt HIMASTA ITS tahun 2012-2013, dan Waka 1 TPKH ITS pada tahun 2013-2014. Apabila pembaca ingin memberikan kritik dan saran atau berdiskusi lebih lanjut mengenai Tugas Akhir ini, pembaca dapat menghubungi penulis melalui *e-mail* : [purwaputraa@yahoo.com](mailto:purwaputraa@yahoo.com).