TUGAS AKHIR – KS 184822

PEMODELAN *MULTIVARIATE ADAPTIVE GENERALIZED POISSON REGRESSION SPLINE* PADA KASUS JUMLAH KEMATIAN IBU DI PROVINSI JAWA TIMUR

EUODIA PUTRI PRASTIKA

NRP 062116 4000 0026

Dosen Pembimbing
Dr. Bambang Widjanarko O., M.Si
Dr. Purhadi, M.Sc

PROGRAM STUDI SARJANA
DEPARTEMEN STATISTIKA
FAKULTAS SAINS DAN ANALITIKA DATA
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2020

TUGAS AKHIR – KS 184822

PEMODELAN *MULTIVARIATE ADAPTIVE GENERALIZED POISSON REGRESSION SPLINE* PADA KASUS JUMLAH KEMATIAN IBU DI PROVINSI JAWA TIMUR

EUODIA PUTRI PRASTIKA

NRP 062116 4000 0026

Dosen Pembimbing
Dr. Bambang Widjanarko O., M.Si
Dr. Purhadi, M.Sc

PROGRAM STUDI SARJANA
DEPARTEMEN STATISTIKA
FAKULTAS SAINS DAN ANALITIKA DATA
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2020

FINAL PROJECT – KS 184822

MULTIVARIATE ADAPTIVE POISSON REGRESSION SPLINE MODELLING NUMBER OF MATERNAL MORTALITY IN EAST JAVA

EUODIA PUTRI PRASTIKA

SN 062116 4000 0026

Supervisors
Dr. Bambang Widjanarko O., M.Si
Dr. Purhadi, M.Sc

UNDERGRADUATE PROGRAMME
DEPARTMENT OF STATISTICS
FACULTY OF SCIENCE AND DATA ANALYTICS
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2020

LEMBAR PENGESAHAN

PEMODELAN *MULTIVARIATE ADAPTIVE GENERALIZED POISSON REGRESSION SPLINE* PADA KASUS JUMLAH KEMATIAN IBU DI PROVINSI JAWA TIMUR

TUGAS AKHIR

Diajukan untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Statistika
pada
Program Studi Sarjana Departemen Statistika
Fakultas Sains dan Analitika Data
Institut Teknologi Sepuluh Nopember
Oleh :

Euodia Putri Prastika
NRP. 062116 4000 0026

Disetujui oleh Pembimbing Tugas Akhir :

Dr. Bambang Widjanarko O., M.Si
NIP. 19681124 199412 1 001 ( )

Dr. Purhadi, M.Sc
NIP. 19620204 198701 1 001 ( )

Mengetahui,
Kepala Departemen

Dr. Dra. Kartika Fithriasari, M.Si.
NIP. 19691212 199303 2 002

SURABAYA, AGUSTUS 2020

PEMODELAN *MULTIVARIATE ADAPTIVE GENERALIZED POISSON REGRESSION SPLINE* PADA KASUS JUMLAH KEMATIAN IBU DI PROVINSI JAWA TIMUR

Nama Mahasiswa	**: Euodia Putri Prastika**
NRP	**: 062116 4000 0026**
Departemen	**: Statistika**
Dosen Pembimbing	**: Dr. Bambang Widjanarko O., M.Si**
	Dr. Purhadi, M.Sc

Abstrak

Ibu berperan penting dalam regenerasi manusia, sehingga keberadaan ibu menjadi perhatian pemerintah. Salah satu masal ah besar yang dialami oleh negara-negara, termasuk Indonesia adalah kematian ibu. Indonesia memiliki angka kematian ibu (AKI) tertinggi kedua di ASEAN, dimana tingginya AKI Indonesia merupakan sumbangsih dari AKI provinsi-provinsi di Indonesia, termasuk Provinsi Jawa Timur. Provinsi Jawa Timur masuk dalam tiga besar AKI tertinggi di Indonesia dengan nilai 91,45 per 100.000 kelahiran hidup pada tahun 2018. Tingginya AKI berbanding positif dengan jumlah kematian ibu, artinya semakin tinggi AKI, maka semakin banyak jumlah kematian ibu. Salah satu upaya yang dapat dilakukan untuk mengurangi AKI adalah pemodelan faktor-faktor yang mempengaruhi jumlah kematian ibu dengan metode regresi. Penelitian ini menggunakan metode Multivariate Adaptive Regression Splines (MARS) dengan estimator generalized Poisson, sehingga menjadi metode Multivariate Adaptive Generalized Poisson Regression Splines (MAGPRS). Model terbaik dari hasil analisis MAGPRS adalah model dengan BF=28, MI=2, dan MO=2. Setelah dilakukan backward stepwise, fungsi basis dari model tersebut menjadi 24, dimana akan menyusun persamaan MAGPRS terbaik. Variabel prediktor yang paling berpengaruh terhadap model secara berurutan adalah variabel persentase ibu nifas mendapat vitamin A, persentase peserta aktif KB, dan persentase kunjungan ibu hamil K4.

Kata Kunci : BF, Jawa Timur, Jumlah Kematian Ibu, MAGPRS, MI, MO

(*Halaman ini sengaja dikosongkan*)

MULTIVARIATE ADAPTIVE POISSON REGRESSION SPLINE MODELLING NUMBER OF MATERNAL MORTALITY IN EAST JAVA

Name : **Euodia Putri Prastika**
SN : **062116 4000 0026**
Department : **Statistics**
Supervisors : **Dr. Bambang Widjanarko O., M.Si**
Dr. Purhadi, M.Sc

Abstract

Mothers play an important role in producing offspring, so the existence of the mother is the concern of the government. One big problem experienced by many countries, including Indonesia, is maternal mortality. Among ASEAN Countries, Indonesia has the second highest maternal mortality ratio (MMR), where the high MMR in Indonesia is contributed by the MMR of Indonesia's provinces, including East Java Province. East Java Province was included in top three highest MMR in Indonesia with 91.45 maternal mortalities per 100,000 live births in 2018. High MMR is proportional to the number of maternal mortalities, signifying that the higher the MMR then the number of maternal mortalities is increasing as well. To reduce the MMR, an effort that can be done is modelling the factors that influence the number of maternal mortalities using the regression method. This research used the Multivariate Adaptive Regression Splines (MARS) method with generalized Poisson estimator, thus became the Multivariate Adaptive Generalized Poisson Regression Splines (MAGPRS) method. The best model of MAGPRS analysis is a model with BF = 28, MI = 2, and MO = 2. After backward stepwise, the basis function of the model changed to 24, which formed the best MAGPRS equation. The most influential predictor variables toward the model sequentially were the percentage of postpartum mothers got vitamin A, the percentage of active birth control participants, and the percentage of visitation to pregnant women K4.

Keywords: BF, Jawa Timur, Number of Maternal Mortality, MAGPRS, MI, MO

(*Halaman ini sengaja dikososngkan*)

KATA PENGANTAR

Puji syukur penulis panjatkan kepada Tuhan Yang Maha Esa yang telah melimpahkan rahmat serta karunia-Nya sehingga penulis dapat menyelesaikan laporan Tugas Akhir yang berjudul **"Pemodelan *Multivariate Adaptive Generalized Poisson Regression Spline* pada Kasus Jumlah Kematian Ibu di Provinsi Jawa Timur"**.

Penulis menyadari bahwa penyusunan Tugas Akhir ini tidak dapat terselesaikan tanpa dukungan berbagai pihak baik berupa dukungan morel, dan materiel. Oleh karena itu, dengan penuh kerendahan hati, pada kesempatan ini penulis mengucapkan terima kasih yang sebesar-besarnya kepada:

1. Orang tua yang selalu memberi dukungan materil maupun yang tidak berupa, seperti doa, semangat, dan motivasi.
2. Bapak Dr. Bambang Widjanarko O., M.Si dan Dr. Purhadi, M.Sc selaku dosen pembimbing atas semua bimbingan, waktu, semangat dan perhatian yang telah diberikan sehingga Tugas Akhir ini dapat diselesaikan dengan baik. Mohon maaf apabila ada kesalahan yang telah penulis lakukan.
3. Bapak Dr. Sutikno, M.Si dan Bapak Jerry Dwi Trijoyo Purnomo, M.Si, Ph.D selaku dosen penguji yang telah memberikan saran dan masukan demi kesempurnaan Tugas Akhir ini.
4. Ibu Dr. Dra. Kartika Fithriasari selaku Kepala Departemen Statistika, Ibu Dr. Santi Wulan Purnami, S.Si, M.Si selaku Sekretaris Departemen Statistika I dan Ibu Dr. Vita Ratnasari, S.Si, M.Si selaku Sekretaris Departemen Statistika II yang telah menyediakan fasilitas untuk mendukung kelancaran penyusunan Tugas Akhir ini.
5. Ibu Dr. Dra. Ismaini Zain, M. Si selaku dosen wali yang telah memberikan pengarahan dan wawasan seputar akademik.
6. Seluruh dosen Departemen Statistika ITS yang telah memberikan ilmu selama penulis menempuh pendidikan, beserta seluruh karyawan Departemen Statistika ITS yang telah membantu kelancaran dan kemudahan dalam pelaksanaan kegiatan perkuliahan.

7. Teman-teman Statistika ITS angkatan 2016, TR16GER, yang selalu memberikan dukungan kepada penulis selama ini.
8. Serta semua pihak yang tidak dapat penulis sebutkan satu persatu.

Penulis menyadari bahwa Tugas Akhir ini masih jauh dari sempurna dikarenakan terbatasnya pengalaman dan pengetahuan yang dimiliki penulis. Oleh karena itu, penulis mengharapkan segala bentuk saran serta masukan bahkan kritik yang membangun dari berbagai pihak. Semoga Tugas Akhir ini dapat bermanfaat bagi para pembaca dan semua pihak.

Surabaya, Agustus 2020

Penulis

DAFTAR ISI

Halaman

HALAMAN JUDUL.....i
COVER PAGE.....iii
LEMBAR PENGESAHAN..... v
ABSTRAK.....vii
ABSTRACT ix
KATA PENGANTAR.....xi
DAFTAR ISI.....xiii
DAFTAR GAMBAR.....xvii
DAFTAR TABEL.....xix
DAFTAR LAMPIRAN xxi
BAB I PENDAHULUAN..... 1
1.1 Latar Belakang..... 1
1.2 Rumusan Masalah 4
1.3 Tujuan Penelitian..... 5
1.4 Manfaat..... 5
1.5 Batasan Masalah..... 5
BAB II TINJAUAN PUSTAKA 7
2.1 Statistika Deskriptif..... 7
2.2 Distribusi Poisson..... 8
2.3 Regresi Poisson 8
2.3.1 Penaksiran Parameter Regresi Poisson…….9
2.4 *Generalized Poisson Regression* (GPR)..... 11
2.4.1 Penaksiran Parameter Model *Generalized Poisson Regression*..... 12
2.4.2 Pengujian Parameter Model *Generalized Poisson Regression*..... 14
2.5 Pengujian *Equidispersion* pada Regresi Poisson..... 15
2.6 *Multivariate Adaptive Regression Spline* (MARS) ... 15
2.6.1 Penaksiran Parameter Model *Multivariate Adaptive Regression Spline* (MARS)..... 18
2.6.2 Pengujian Parameter Model *Multivariate Adaptive Regression Spline* (MARS)..... 19
2.6.3 *Generalized Cross Validation* (GCV)..... 20

2.7 Koefisien Korelasi 21
2.8 *Multivariate Adaptive Generalized Poisson Regression Spline* (MAGPRS) 22
2.8.1 Penaksiran Parameter Model *Multivariate Adaptive Generalized Poisson Regression Spline* (MAGPRS)..... 23
2.8.2 Pengujian Parameter Model *Multivariate Adaptive Generalized Poisson Regression Spline* (MAGPRS)..... 28
2.9 Kematian Ibu 34
2.10 Kerangka Konsep Penelitian 36
BAB III METODOLOGI PENELITIAN 399
3.1 Sumber Data 40
3.2 Variabel Penelitian 40
3.3 Struktur Data 41
3.4 Langkah Penelitian 42
3.5 Diagram Alir 42
BAB IV ANALISIS DAN PEMBAHASAN 44
4.1 Karakteristik Jumlah Kematian Ibu di Jawa Timur Tahun 2018 dan Faktor-Faktor yang Diduga Berpengaruh 44
4.1.1 Statistika Deskriptif Jumlah Kematian Ibu di Jawa Timur Tahun 2018 dan Faktor-Faktor yang Diduga Berpengaruh..... 46
4.1.2 Pola Hubungan Jumlah Kematian Ibu di Jawa Timur Tahun 2018 dan Faktor-Faktor yang Diduga Berpengaruh..... 49
4.2 Pemodelan Jumlah Kematian Ibu di Jawa Timur Tahun 2018 dengan *Multivariate Adaptive Generalized Poisson Regression Spline* ..... (MAGPRS) 51
4.2.1 Pendeteksi Equidispersi..... 51
4.2.2 Model MAGPRS Terbaik pada Jumlah Kematian Ibu..... 52

4.2.3 Pengujian Simultan Model MAGPRS Terbaik……..... 54
4.2.4 Pengujian Parsial Parameter Model MAGPRS Terbaik..…… 55
4.2.5 Interpretasi Model MAGPRS Terbaik…….. 56
BAB V KESIMPULAN DAN SARAN..... 68
5.1 Kesimpulan..... 68
5.2 Saran..... 69
DAFTAR PUSTAKA 70
LAMPIRAN..... 733
BIODATA PENULIS..... 92

(*Halaman ini sengaja dikosongkan*)

DAFTAR GAMBAR

Halaman

Gambar 3.1 Diagram Alir 43
Gambar 4.1 Jumlah Kematian Ibu pada Setiap Kabupaten/Kota di Jawa Timur 45
Gambar 4.2 *Scatterplot* Jumlah Kematian Ibu dan Faktor-Faktor yang Diduga Berpengaruh 49

(*Halaman ini sengaja dikosongkan*)

DAFTAR TABEL

Halaman

Tabel 3.1 Data Penelitian.....40
Tabel 3.2 Struktur Data Penelitian.....41
Tabel 4.1 Statistika Deskriptif Jumlah Kematian Ibu dan Faktor-Faktor yang Diduga Berpengaruh 46
Tabel 4.2 Nilai Korelasi dan P-*value* Variabel Prediktor terhadap Variabel Respon 50
Tabel 4.3 Pengujian Equidispersi dengan Uji Khi Kuadrat Pearson 52
Tabel 4.4 Hasil Percobaan Pembentukan Model MAGPRS antara Jumlah Kematian Ibu dengan Faktor-Faktor yang Diduga Berpengaruh.....53
Tabel 4.5 Hasil Pengujian Simultan Model MAGPRS Terbaik 54
Tabel 4.6 Hasil Pengujian Parsial Parameter Model MAGPRS Terbaik 55

(*Halaman ini sengaja dikosongkan*)

DAFTAR LAMPIRAN

Halaman

Lampiran 1. Data Jumlah Kematian Ibu di Jawa Timur Tahun 2018 dan Faktor-Faktor yang Diduga Berpengaruh ..74
Lampiran 2. *Output* R Uji Equidispersi 75
Lampiran 3. *Output* Estimasi Parameter MAGPRS 75
Lampiran 4. *Output* Matriks Bobot WLS 76
Lampiran 5. *Output* BHHH Parameter Dispersi 76
Lampiran 6. *Output* Hasil Uji Serentak 77
Lampiran 7. *Output* Estimasi Parameter dan Hasil Uji Parsial 77
Lampiran 8. *Syntax* Uji Equidispersi 78
Lampiran 9. *Syntax* Estimasi Parameter MAGPRS 78
Lampiran 10. Surat Pernyatan Data Sekunder 89

(*Halaman ini sengaja dikosongkan*)

BAB I

PENDAHULUAN

1.1 Latar Belakang

Seorang ibu diciptakan secara istimewa dapat menghasilkan keturunan (anak). Ibu berperan penting dalam regenerasi manusia, sehingga keberadaan ibu menjadi perhatian pemerintah di seluruh negara, termasuk Negara Indonesia. Masalah yang seringkali terjadi di Indonesia adalah kematian ibu. Kematian ibu adalah kematian yang terjadi saat kehamilan, atau selama 42 hari sejak terminasi kehamilan, tanpa memperhitungkan durasi dan tempat kehamilan, yang disebabkan atau diperparah oleh kehamilan atau pengelolaan kehamilan tersebut, tetapi bukan disebabkan oleh kecelakaan atau kebetulan (WHO, 2004). Kematian ibu disebabkan oleh komplikasi saat kehamilan dan pasca kehamilan. Bentuk komplikasi yang menyebabkan kematian ibu antara lain pendarahan, infeksi, tekanan darah tinggi saat kehamilan, komplikasi persalinan, dan aborsi yang tidak aman. Banyak program yang dicanangkan pemerintah Indonesia untuk mencegah kematian ibu berdasarkan program pembangunan berkelanjutan. Pembangunan berkelanjutan sendiri merupakan proses pembangunan (lahan, kota, bisnis, masyarakat, dan lain-lain) yang berprinsip "memenuhi kebutuhan sekarang tanpa mengorbankan pemenuhan kebutuhan generasi masa depan" (World Commission, 1987). Bersama dengan negara-negara Perserikatan Bangsa-Bangsa (PBB), Indonesia menyepakati dokumen "Transforming Our World: The 2030 Agenda for Sustainable Development" yaitu agenda pembangunan berkelanjutan tahun 2030. Dokumen tersebut dibuat sebagai dasar pembangunan di negara-negara anggota PBB. Kesepakatan tersebut mengganti Millenium Development Goals (MGDs) yang berakhir tahun 2015 menjadi Sustainable Development Goals (SDGs) periode 2015-2030. SDGs terdiri atas 17 tujuan yang terbagi menjadi 169 target yang harus tercapai pada tahun 2030. Salah satu tujuannya adalah memastikan kehidupan yang sehat dan mendukung kesejahteraan bagi semua

untuk semua usia (tujuan ke-3). Tujuan tersebut memiliki beberapa target, salah satunya adalah mengurangi rasio angka kematian ibu menjadi kurang dari 70 per 100.000 kelahiran. Definisi rasio kematian ibu atau Angka Kematian Ibu (AKI) menurut BPS adalah banyaknya kematian perempuan pada saat hamil atau selama 42 hari sejak terminasi kehamilan tanpa memandang lama dan tempat persalinan, yang disebabkan karena kehamilannya atau pengelolaannya, dan bukan karena sebab-sebab lain, per 100.000 kelahiran hidup. Berdasarkan Survei Penduduk Antar Sensus (SUPAS) pada tahun 2015, AKI di Indonesia mencapai angka 305 per 100.000 kelahiran dan menduduki rangking ke-2 terbanyak di ASEAN (ASEAN Secretariat, 2017). Angka tersebut masih jauh dari target SDGs 2030.

Besarnya AKI di Indonesia tidak luput dari sumbangsih AKI provinsi-provinsi di Indonesia. Menurut United States Agency International Development (USAID) melalui program JALIN 2018, Provinsi Jawa Timur masuk tiga besar AKI tertinggi di Indonesia. AKI Provinsi Jawa Timur adalah 91,45 per 100.000 kelahiran hidup pada tahun 2018, yang berarti 92 kematian ibu yang disebabkan karena kehamilan, persalinan sampai 42 hari setelah melahirkan pada periode tersebut per 100.000 kelahiran hidup. Angka tersebut mengalami penurunan dari tahun 2017 yang mencapai 91,92 per 100.000 kelahiran hidup. Menurut Dinas Kesehatan Pemerintah Provinsi Jawa Timur ada tiga daerah di Jawa Timur yang memiliki AKI tertinggi, yaitu Kota Pasuruhan, Kota Blitar, dan Kabupaten Bondowoso pada tahun 2018. AKI tersebut harus selalu diupayakan turun, agar kasus kematian ibu dapat berkurang, sehingga tercipta kesehatan dan kesejahteraan bagi semua usia, sesuai dengan isi SDGs 2030.

Menurut BPS, AKI diperoleh dari jumlah kematian ibu dalam tahap hamil atau kelahiran dibagi dengan jumlah kelahiran hidup. Tingginya jumlah kematian ibu berbanding positif dengan AKI, artinya semakin banyak jumlah kematian ibu maka nilai AKI akan semakin tinggi. Salah satu upaya pencegahan jumlah kematian ibu yang semakin tinggi adalah dengan memodelkan jumlah kematian

ibu dari faktor-faktor yang diduga mempengaruhi, agar dapat diketahui faktor apa saja yang berpengaruh signifikan terhadap jumlah kematian ibu. Pemodelan ini membutuhkan informasi pola hubungan antara variabel prediktor terhadap variabel respon yang dapat dilakukan melalui analisis regresi. Namun apabila tidak terdapat informasi mengenai bentuk fungsi dan tidak jelasnya pola hubungan antara variabel prediktor dengan variabel respon maka analisis dapat dilakukan menggunakan pendekatan regresi nonparametrik (Eubank, 1999). Pendekatan regresi nonparametrik dapat memodelkan fungsi secara fleksibel sesuai dengan data yang ada. Salah satu model pendekatan regresi nonparametrik yakni metode Multivariate Adaptive Regression Splines (MARS). Metode MARS memiliki kelebihan relatif fleksibel dan inovatif untuk menyelidiki pola hubungan antara variabel tanpa asumsi terhadap bentuk fungsionalnya. Metode ini difokuskan untuk mengatasi permasalahan dimensi tinggi, memperoleh prediksi nilai respon yang akurat, dan menghasilkan model knot yang kontinu berdasarkan nilai *generalized cross validation* (GCV) paling kecil (Otok dkk, 2014). Metode ini juga melibatkan banyak interaksi antar variabel (Friedman, 1991). Penelitian ini menggunakan estimator *generalized* Poisson pada metode MARS, sehingga menjadi metode kombinasi Multivariate Adaptive Generalized Poisson Regression Splines (MAGPRS). Hal ini dilakukan karena pola data tidak linier, variabel respon merupakan variabel *count* (jumlah), dan diduga berdistribusi Poisson. *Generalized* Poisson digunakan karena diduga asumsi distribusi Poisson tidak terpenuhi, yaitu nilai rata-rata tidak sama dengan varians.

Kajian mengenai MARS dilakukan oleh (Nahriyah, 2017) untuk mengklasifikasikan pasien HIV/AIDS di Kabupaten Pasuruhan dengan membandingkan 2 metode yaitu MARS dan Bagging MARS. Penelitian tersebut memodelkan Infeksi Opurtunistik (IO) yang merupakan jenis gangguan penyerta (penyakit infeksi selain HIV) pada penderita penyakit HIV/AIDS seperti TB paru, hepatitis, sipilis, dan lain sebagainya berdasarkan diagnosa dokter, dimana hasilnya adalah klasifikasi kejadian IO

pada data training sama-sama tepat menggunakan kedua metode MARS maupun Bagging MARS, sedangkan untuk data testing lebih tepat jika menggunakan metode Bagging MARS. Kajian mengenai metode MAGPRS dilakukan oleh (Hidayati, 2019) untuk menaksiran parameter dan statistik uji model MAGPRS pada kasus jumlah penderita ISPA pada bayi di Surabaya tahun 2017. Hasil yang didapatkan adalah penaksiran parameter metode MAGPRS didapatkan dengan menggunakan metode Weighted Least Square (WLS) dan pengujian parameter MAGPRS didapatkan dengan menggunakan metode Maximum Likelihood Ratio Test (MLRT). Kajian mengenai jumlah kematian ibu dilakukan oleh (Wardani, 2015) yaitu untuk memodelkan faktor-faktor yang memperngaruhi jumlah kematian ibu di Jawa Timur Tahun 2013 dengan menggunakan regresi binomial negatif. Hasil yang didapatkan adalah persentase penanganan ibu hamil mengalami komplikasi, persentase ibu nifas mendapatkan vitamin A, persentase ibu hamil mendapatkan tablet Fe_3, rasio sarana kesehatan rumah sakit dan rasio sarana kesehatan puskesmas adalah variabel-variabel penelitian yang signifikan mempengaruhi kematian ibu. Kajian selanjutnya mengenai jumlah kematian ibu dilakukan oleh (Khotimah, 2016) yaitu memodelkan jumlah kematian ibu di Jawa Timur dengan regresi panel. Variabel yang signifikan mempengaruhi kematian ibu antara lain persentase cakupan pelayanan antenatal K4 dan persentase kelahiran yang ditolong oleh tenaga kesehatan.

1.2 Rumusan Masalah

Jumlah kematian ibu di Jawa Timur cenderung tinggi dan berpengaruh terhadap tingginya AKI Indonesia tahun 2018. Hal ini menunjukkan bahwa pemerintah Indonesia belum dapat mencapai SDGs 2030, khususnya pada tujuan memastikan kehidupan yang sehat dan mendukung kesejahteraan bagi semua untuk semua usia. Oleh karena itu peneliti melakukan penelitian terhadap faktor-faktor yang berpengaruh terhadap jumlah kematian ibu di Provinsi Jawa Timur menggunakan model MAGPRS, agar dapat dilakukan langkah preventif atau pencegahan secara efektif.

1.3 Tujuan Penelitian

Berdasarkan rumusan masalah yang telah disebutkan, tujuan yang ingin dicapai pada penelitian ini adalah untuk mengetahui faktor-faktor yang berpengaruh terhadap jumlah kematian ibu di Provinsi Jawa Timur menggunakan model MAGPRS. Hal ini bertujuan untuk mencegah jumlah kematian ibu yang semakin tinggi, sehingga SDGs 2030 di Indonesia dapat terlaksana dengan maksimal.

1.4 Manfaat

Manfaat yang ingin dicapai dalam penelitian ini adalah sebagai berikut.

1. Bagi pembaca, memberi tambahan pengetahuan tentang penerapan metode *Multivariate Adaptive Generalized Poisson Regression Spline* pada kasus jumlah kematian ibu.
2. Memberikan informasi sebagai bahan pertimbangan bagi pemerintah Provinsi Jawa Timur dalam pengambilan kebijakan untuk menurunkan jumlah kematian ibu di Jawa Timur
3. Bagi penulis, dapat dijadikan bahan belajar pengaplikasian metode *Multivariate Adaptive Generalized Poisson Regression Spline* dalam bidang lingkungan dan kesehatan.

1.5 Batasan Masalah

Penelitian ini menggunakan data jumlah kematian ibu di Provinsi Jawa Timur pada tahun 2018. Unit observasi penelitian ini adalah 38 Kabupaten/Kota di Jawa Timur.

(Halaman ini sengaja dikosongkan)

BAB II

TINJAUAN PUSTAKA

2.1 Statistika Deskriptif

Statistika deskriptif adalah metode untuk meringkas suatu data agar menghasilkan informasi yang mudah dipahami. Statistika deskriptif seringkali digunakan untuk menunjukkan karakteristik dari suatu data, seperti pusat lokasi data, variabilitas dari data, dan sifat umum dari distribusi data (Walpole dkk, 2016). Statistika deskriptif hanya memberikan informasi mengenai data yang dimiliki dan tidak dapat menarik suatu kesimpulan terhadap sekumpulan data. Statistika deskriptif yang digunakan pada penelitian ini adalah ukuran pemusatan data (rata-rata) dan ukuran penyebaran data (varians, nilai maksimum dan nilai minimum). Visualisai data yang digunakan pada penelitian ini adalah diagram pencar (*scatterplot*) untuk menjelaskan hubungan antara dua variable respon dan vaiabel prediktor.

Rata-rata adalah hasil pembagian antara penjumlahan nilai setiap pengamatan dengan banyaknya data pengamatan. Persamaan rataan sampel tertulis pada persamaan 2.1 (Walpole dkk, 2016).

$$\bar{x} = \frac{\sum_{i=1}^{n} x_i}{n} \tag{2.1}$$

dimana $\bar{x}$ adalah rata-rata, x_i adalah pengamatan ke-*i*, i=1,2,...,*n*, dan *n* adalah banyak data pengamatan.Varians merupakan kuadrat simpangan dari semua nilai data terhadap rata-rata. Persaamaan varians sampel dituliskan dengan pada persamaan 2.2 (Walpole dkk, 2016).

$$s^2 = \frac{\sum_{i=1}^{n} \left(x_i - \bar{x}\right)^2}{n-1} \tag{2.2}$$

dimana s^2 merupakan varians data, n merupakan ukuran sampel data, dan x_i adalah data ke-*i*. Nilai maksium adalah nilai terbesar

dari kumpulan data, sedangkan nilai minimum adalah nilai terkecil dari kumpulan data.

2.2 Distribusi Poisson

Distribusi Poisson adalah distribusi yang mengalami proses Poisson. Distribusi ini mewakili jumlah hasil yang terjadi pada suatu wilayah tertentu (garis, luasan, volume, atau sepotong bahan) atau interval waktu tertentu (semenit, sehari, seminggu, sebulan, atau setahun), dimana hasil pengamatannya adalah variabel diskrit (Walpole dkk, 2016). Ciri-ciri percobaan yang mengikuti distribusi Poisson adalah kejadian yang terjadi pada populasi yang besar memiliki probabilitas yang kecil, kejadian bergantung pada selang waktu tertentu, kejadian termasuk dalam *counting process*, dan perulangan dari kejadian mengikuti distribusi binomial.

Fungsi peluang variabel random *Y* yang memiliki distribusi Poisson adalah sebagai berikut (Mood, Graybill, dan Boes, 1974).

$$f_y(y) = f_y(y,\mu) = \begin{cases} \dfrac{e^{-\mu}\mu^y}{y!}\ ; y = 0,1,2,.. \\ 0; selainnya \end{cases} \qquad (2.3)$$

dimana nilai $\mu > 0$. Semakin kecil nilai μ, maka distribusinya semakin menceng, sedangkan semakin besar nilai μ, maka semakin mendekati distribusi normal. Rataan dan variansi dalam distribusi Poisson dituliskan pada persamaan 2.4 (Mood, Graybill, dan Boes, 1974).

$$E(Y) = Var(Y) = \mu \qquad (2.4)$$

2.3 Regresi Poisson

Regresi Poisson merupakan regresi untuk memodelkan data cacahan / *count* (Agresti, 2002). Regresi Poisson termasuk regresi yang nonlinier (Cameron dan Trivedi, 1998). Regresi Poisson menggambarkan hubungan antara antara variabel respon *Y* dan variabel prediktor *X* dengan mengasumsikan variabel *Y* berdistribusi Poisson. Jika pendekatannya secara parametrik dan melibatkan kovariat eksogen tetapi tidak ada sumber variasi

stokastik lainnya, maka regresi Poisson standar. Jika fungsi berkaitan dengan μ dan kovariatnya stokastik, maka regresi Poisson campuran (Cameron dan Trivedi, 1998).

Model regresi Poisson (log-linier) didefinisikan secara bersamaan pada persamaan (2.5).

$$f(y_i \mid \boldsymbol{x}_i) = \frac{e^{-\mu_i}\mu_i^{y_i}}{y_i!}, y_i = 0,1,2,....$$

$$\mu_i = \exp(\boldsymbol{x}^T{}_i\beta) \Leftrightarrow \ln(\mu_i) = \boldsymbol{x}^T{}_i\beta \qquad (2.5)$$

dimana $\mu > 0$ (Cameron dan Trivedi, 1998).

2.3.1 Penaksiran Parameter Regresi Poisson

Penaksiran parameter regresi Poisson menggunakan *Maximum Likelihood Estimation* (MLE) dengan taksiran maksimum dari model regresi Poisson (Cameron dan Trivedi, 1998). Bentuk umum dari fungsi *likelihood* model regresi Poisson sebagai berikut.

$$L(\boldsymbol{\beta}) = \prod_{i=1}^{n} f(y_i, \boldsymbol{\beta})$$

$$= \prod_{i=1}^{n} \left(\frac{\left[\mu(\boldsymbol{x_i}, \boldsymbol{\beta})\right]^{y_i} exp\left[-\mu(\boldsymbol{x_i}, \boldsymbol{\beta})\right]}{y_i!} \right) \qquad (2.6)$$

dimana $\left[\mu\left(x_i, \boldsymbol{\beta}\right)\right] = exp\left(\boldsymbol{x_i^T \beta}\right)$

$$L(\boldsymbol{\beta}) = \prod_{i=1}^{n} \left(\left[exp\left(\boldsymbol{x_i}^T \boldsymbol{\beta}\right)^{y_i} \right] \frac{exp\left[-exp\left(\boldsymbol{x_i}^T \boldsymbol{\beta}\right)\right]}{y_i!} \right)$$

$$= \left(\frac{\prod_{i=1}^{n} \left[exp\left(\boldsymbol{x_i}^T \boldsymbol{\beta}\right)^{y_i} \right] exp\left[-\sum_{i=1}^{n}\left(\boldsymbol{x_i}^T \boldsymbol{\beta}\right)\right]}{\prod_{i=1}^{n} y_i!} \right)$$

Selanjutnya adalah menurunkan $ln\, L(\boldsymbol{\beta})$ terhadap $\boldsymbol{\beta}$, kemudian disamadengankan nol (Cameron dan Trivedi, 1998).

$$ln\,L(\boldsymbol{\beta}) = \sum_{i=1}^{n} y_i \left(\boldsymbol{x_i}^{\boldsymbol{T}} \boldsymbol{\beta}\right) - \sum_{i=1}^{n} exp\left(\boldsymbol{x_i}^{\boldsymbol{T}} \boldsymbol{\beta}\right) - \sum_{i=1}^{n} y_i ! \qquad (2.7)$$

Turunan pertama dan kedua adalah sebagai berikut.

$$\frac{\partial ln\,L(\boldsymbol{\beta})}{\partial \boldsymbol{\beta}^{\boldsymbol{T}}} = \sum_{i=1}^{n} y_i \boldsymbol{x_i} - \sum_{i=1}^{n} \boldsymbol{x_i} \exp(\boldsymbol{x_i}^{\boldsymbol{T}} \boldsymbol{\beta}) \qquad (2.8)$$

$$\frac{\partial^2 ln\,L(\boldsymbol{\beta})}{\partial \boldsymbol{\beta} \partial \boldsymbol{\beta}^{\boldsymbol{T}}} = -\sum_{i=1}^{n} \boldsymbol{x_i} \boldsymbol{x_i}^{\boldsymbol{T}} \exp(\boldsymbol{x_i}^{\boldsymbol{T}} \boldsymbol{\beta}) \qquad (2.9)$$

Persamaan tersebut tidak dapat diselesaikan secara analitik, sehingga untuk menyelesaikannya menggunakan metode iterasi Newton-Rhapson (Cameron dan Trivedi, 1998), dimana persamaannya sebagai berikut.

$$\hat{\boldsymbol{\beta}}_{(m+1)} = \hat{\boldsymbol{\beta}}_{(\mathrm{m})} - \mathbf{H}^{(-1)}(\hat{\boldsymbol{\beta}}_{(\mathrm{m})}) g(\hat{\boldsymbol{\beta}}_{(\mathrm{m})}) \qquad (2.10)$$

dimana $\widehat{\boldsymbol{\beta}}_{(m)}$ adalah nilai taksiran parameter pada saat iterasi ke-*m*. $\boldsymbol{g}(\widehat{\boldsymbol{\beta}}_{(m)})$ adalah vektor gradient dengan parameter $(\widehat{\boldsymbol{\beta}}_{(m)})$,

$$\boldsymbol{g}\left(\hat{\boldsymbol{\beta}}_{(m)}\right) = \left[\begin{array}{c} \dfrac{\partial ln\,L(\boldsymbol{\beta})}{\partial \beta_0} \\ \dfrac{\partial ln\,L(\boldsymbol{\beta})}{\partial \beta_1} \\ \vdots \\ \dfrac{\partial ln\,L(\boldsymbol{\beta})}{\partial \beta_k} \end{array}\right]_{\boldsymbol{\beta}=\hat{\boldsymbol{\beta}}_{(m)}} \qquad (2.11)$$

dimana *k* adalah banyaknya parameter yang ditaksir (Cameron dan Trivedi,1998). $\boldsymbol{H}(\widehat{\boldsymbol{\beta}}_{(m)})$ adalah matriks Hessian dengan parameter $\widehat{\boldsymbol{\beta}}_{(m)}$ (Cameron dan Trivedi,1998),

$$H\left(\hat{\boldsymbol{\beta}}_{(m)}\right)=\begin{bmatrix} \frac{\partial^2 \ln L(\boldsymbol{\beta})}{\partial \beta_0{}^2} & \frac{\partial^2 \ln L(\boldsymbol{\beta})}{\partial \beta_0 \partial \beta_1} & \cdots & \frac{\partial^2 \ln L(\boldsymbol{\beta})}{\partial \beta_0 \partial \beta_k} \\ \frac{\partial^2 \ln L(\boldsymbol{\beta})}{\partial \beta_0 \partial \beta_1} & \frac{\partial^2 \ln L(\boldsymbol{\beta})}{\partial \beta_1{}^2} & \cdots & \frac{\partial^2 \ln L(\boldsymbol{\beta})}{\partial \beta_1 \partial \beta_k} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 \ln L(\boldsymbol{\beta})}{\partial \beta_0 \partial \beta_k} & \frac{\partial^2 \ln L(\boldsymbol{\beta})}{\partial \beta_1 \partial \beta_k} & \cdots & \frac{\partial^2 \ln L(\boldsymbol{\beta})}{\partial \beta_k{}^2} \end{bmatrix}_{\boldsymbol{\beta}=\hat{\boldsymbol{\beta}}_{(m)}} \tag{2.12}$$

Taksiran awal $\widehat{\boldsymbol{\beta}}_{(0)}$ menggunakan metode *Ordinary Least Square* (OLS), sebagai berikut (Draper dan Smith, 1998).

$$\hat{\boldsymbol{\beta}}_{(0)}=\left(X^T X\right)^{-1} X^T Y \tag{2.13}$$

$\widehat{\boldsymbol{\beta}}_{(0)}$ akan di subtitusikan pada elemen-elemen vektor gradient $\boldsymbol{g}$ dan matriks hessian **H,** sehingga diperoleh $\widehat{\boldsymbol{g}}(\boldsymbol{\beta}_{(\mathbf{0})})$ dan $\widehat{\boldsymbol{H}}(\boldsymbol{\beta}_{(\mathbf{0})})$. Selanjutnya dilakukan iterasi mulai dari *m=0,* dan iterasi akan berhenti jika nilai$\left\|\widehat{\boldsymbol{\beta}}_{(m+1)}-\widehat{\boldsymbol{\beta}}_{(m)}\right\|<\varepsilon$, dimana $\varepsilon>0$ dan sangat kecil.

2.4 *Generalized Poisson Regression* (GPR)

Metode GPR dikembangkan untuk menangani pelanggaran asumsi distribusi Poisson, yaitu rata-rata tidak sama dengan varians (Melliana dkk, 2013). Metode ini merupakan salah satu model untuk mengatasi permasalah *over/under dispersion*. Model GPR memiliki tambahan parameter parameter θ sebagai parameter dispersi. Model *Generalized Poisson* yang merupakan suatu model *Generalized Linear Model* namun mengasumsikan komponen random berdistribusi *Generalized Poisson*. Persamaan model *Generalized Poisson* adalah sebagai berikut (Famoye, Wulu, dan Sigh, 2004).

$$f\left(y_i;\mu,\theta\right)=\left(\frac{\mu}{1+\theta\mu}\right)^{y_i}\frac{\left(1+\theta\mu\right)^{\left(y_i-1\right)}}{y_i!}exp\left(\frac{-\mu(1+\theta y_i}{1+\theta\mu}\right),$$

$$y_i = 0,1,2,\ldots \tag{2.14}$$

Dimana nilai $\mu > 0$ dan $-\infty < \theta < \infty$. *Mean* dan *varians* adalah sebagai berikut.

$$E(y_i) = \mu \qquad Var(y_i) = \mu\left(1+\theta\mu\right)^2 \tag{2.15}$$

Model GPR adalah sebagai berikut.

$$\mu(\boldsymbol{x}) = \exp(\boldsymbol{x}^{\boldsymbol{T}}\boldsymbol{\beta}) \tag{2.16}$$

2.4.1 Penaksiran Parameter Model *Generalized Poisson Regression*

Penaksiran parameter regresi *Generalized Poisson* menggunakan *Maximum Likelihood Estimation* (MLE) dengan taksiran maksimum dari model regresi Poisson. Bentuk umum dari fungsi *likelihood* model regresi *Generalized Poisson* sebagai berikut.

$$L\left(\mu_i,\theta\right) = \prod_{i=1}^{n}\left[\left(\frac{\mu_i}{1+\theta\mu_i}\right)^{y_i}\frac{\left(1+\theta y_i\right)^{\left(y_i-1\right)}}{y_i!}exp\left(\frac{-\mu_i(1+\theta y_i}{1+\theta\mu_i}\right)\right]$$

$$= \prod_{i=1}^{n}\left(\frac{\mu_i}{1+\theta\mu_i}\right)^{y_i}\prod_{i=1}^{n}\frac{\left(1+\theta y_i\right)^{\left(y_i-1\right)}}{y_i!}exp\left(\frac{-\mu_i(1+\theta y_i}{1+\theta\mu_i}\right) \tag{2.17}$$

Fungsi $ln\, L(\mu_i,\theta)$ adalah sebagai berikut.

$$ln\,L\left(\mu_i,\theta\right) = ln\left\{\prod_{i=1}^{n}\left[\left(\frac{\mu_i}{1+\theta\mu_i}\right)^{y_i}\frac{\left(1+\theta y_i\right)^{\left(y_i-1\right)}}{y_i!}exp\left(\frac{-\mu_i\left(1+\theta y_i\right)}{1+\theta\mu_i}\right)\right]\right\} \tag{2.18}$$

$$= \sum_{i=1}^{n} y_i ln(\mu_i) - y_i ln(1+\theta\mu_i) + (y_i-1)ln(1+\theta y_i) - ln(y_i!)$$

$$-\left(\frac{\mu_i\left(1+\theta y_i\right)}{1+\theta\mu_i}\right)$$

dimana $\mu_i = \exp\left(\boldsymbol{x_i}^{\boldsymbol{T}}\boldsymbol{\beta}\right)$

$$ln\,L(\mu_i,\theta)=\sum_{i=1}^{n}\Bigg[y_i\ln\left(exp\left(\boldsymbol{x_i^T\beta}\right)\right)-y_i\ln\left(1+\theta\exp\left(\boldsymbol{x_i^T\beta}\right)\right)+$$

$$(y_i-1)ln(1+\theta y_i)-ln(y_i!)-\frac{\exp\left(\boldsymbol{x_i^T\beta}\right)(1+\theta y_i)}{1+\theta\exp(\boldsymbol{x_i^T\beta})}\Bigg]$$

$$=\sum_{i=1}^{n}\Bigg[y_i\left(\boldsymbol{x_i^T\beta}\right)-y_i\ln\left(1+\theta\exp\left(\boldsymbol{x_i^T\beta}\right)\right)+(y_i-1)\ln(1+\theta y_i)-\ln(y_i!)$$

$$-\frac{\exp\left(\boldsymbol{x_i^T\beta}\right)(1+\theta y_i)}{1+\theta\exp(\boldsymbol{x_i^T\beta})}\Bigg]\text{ (Melliana dkk, 2013)}\qquad(2.19)$$

Selanjutnya persamaan (2.19) diturunkan terhadap $\boldsymbol{\beta^T}$, kemudian disamadenganken nol. Hal tersebut dilakukan untuk mendapatkan nilai $\widehat{\boldsymbol{\beta}}$.

$$\frac{\partial ln\,L(\boldsymbol{\beta},\theta)}{\partial\boldsymbol{\beta^T}}=\sum_{i=1}^{n}\Bigg\{y_i\boldsymbol{x_i}-\frac{\theta y_i\boldsymbol{x_i}\ \exp\left(\boldsymbol{x_i^T\beta}\right)}{1+\theta\exp\left(\boldsymbol{x_i^T\beta}\right)}-(1+\theta y_i)\Bigg[\left(\frac{\boldsymbol{x_i}\ \exp\left(\boldsymbol{x_i^T\beta}\right)}{1+\theta\exp\left(\boldsymbol{x_i^T\beta}\right)}\right)$$

$$-\left(\frac{\theta\boldsymbol{x_i}\left(\exp\left(\boldsymbol{x_i^T\beta}\right)\right)^2}{\left(1+\theta\exp\left(\boldsymbol{x_i^T\beta}\right)\right)^2}\right)\Bigg]\Bigg\}$$

Selanjutnya persamaan (2.19) diturunkan terhadap θ, kemudian disamadenganken nol. Hal tersebut dilakukan untuk mendapatkan nilai θ.

$$\frac{\partial ln\,L(\boldsymbol{\beta},\theta)}{\partial\theta}=\sum_{i=1}^{n}\Bigg\{-y_i\ \exp\left(\boldsymbol{x_i^T\beta}\right)\left(1+\theta\exp\left(\boldsymbol{x_i^T\beta}\right)\right)^{-1}$$

$$+y_i(y_i-1)(1+\theta y_i)^{-1}-\exp\left(\boldsymbol{x_i^T\beta}\right)$$

$$\left[y_i\left(1+\theta\exp\left(\boldsymbol{x_i^T\beta}\right)\right)^{-1}-(1+\theta y_i)\exp\left(\boldsymbol{x_i^T\beta}\right)\left(1+\theta\exp\left(\boldsymbol{x_i^T\beta}\right)\right)^{-2}\right]\Bigg\}$$

Penurunan fungsi *ln-likelihood* terhadap $\boldsymbol{\beta}^{\boldsymbol{T}}$ dan θ menghasilkan persamaan yang implisit sehingga alternative penyelesaian menggunakan metode interasi Newton-Raphson, seperti pada persaamaan (2.10).

2.4.2 Pengujian Parameter Model *Generalized Poisson Regression*

Pengujian parameter model regresi *generalized Poisson* dengan menggunkan *Maximum Likelihood Ratio Test* (MLRT). Pengujian MLRT untuk parameter β terdiri atas pengujian secara serentak dan parsial. Hipotesis pengujian MLRT untuk parameter β secara serentak ini adalah sebagai berikut.

$H_0 : \beta_1 = \beta_2 = \beta_3 = \cdots = \beta_k = 0$

H_1 : minimal ada satu $\beta_j \neq 0,\ j = 1,2,3, \ldots, k$

Statistik uji pengujian MLRT secara serentak adalah sebagai berikut (Agresti, 2002).

$$D\left(\hat{\boldsymbol{\beta}}\right) = -2\ln\Lambda = -2\ln\left(\frac{L\left(\hat{\omega}\right)}{L\left(\hat{\Omega}\right)}\right) \tag{2.20}$$

Tolak H_0 ketika $D\left(\hat{\boldsymbol{\beta}}\right) > x^2_{\alpha,df}$. Jika diperoleh keputusan H_0, maka dilanjutkan ke pengujian parsial, dimana hipotesisnya adalah sebagai berikut.

$H_0 : \beta_j = 0$ (variabel ke-*i* tidak berpengaruh signifikan terhadap model)

$H_1 : \beta_j \neq 0,\ j = 1,2,3, \ldots, k$ (variabel ke-*i* berpengaruh signifikan terhadap model),

Statistik uji pengujian MLRT untuk parameter β secara parsial adalah sebagai berikut.

$$Z = \frac{\hat{\beta}_j}{se\left(\hat{\beta}_j\right)} \tag{2.21}$$

$se\left(\hat{\beta}_j\right) = \sqrt{\widehat{Var}(\hat{\beta}_j)}$. $\widehat{Var}(\hat{\beta}_j)$ adalah elemen diagonal ke (j+1) dari $Var(\hat{\boldsymbol{\beta}})$, dimana $\widehat{Var}(\hat{\boldsymbol{\beta}}) = -\boldsymbol{H}^{-1}(\hat{\boldsymbol{\beta}})$. Tolak H_0 jika $\left|Z_{hitung}\right| > Z_{\alpha/2}$.

2.5 Pengujian *Equidispersion* pada Regresi Poisson

Ciri distribusi Poisson adalah rata-rata dan varians sama (*equidispersion*), namun pada prakteknya terkadang ditemukan suatu kondisi dimana rata-rata data lebih besar atau kecil dibandingkan dengan varians. Kondisi ini disebut *over dispersion* dan *under dispersion.* Akibat yang dihasilkan adalah model menjadi tidak sesuai. Selain itu, akan menghasilkan penaksiran parameter yang bias.

Kasus *equidispersion* dapat dideteksi dengan statistika Khi Kuadrat Pearson. Nilai ini sama dengan rasio varians terhadap rata-rata (*variance-to-mean ratio*) atau disebut indeks disperse. Jika nilai disperse kurang dari 1 maka dikatakan underdispersi, dan sebaliknya jika nilai disperse lebih dari 1 maka overdispersi, dimana statistik uji Khi Kuadrat Pearson adalah sebagai berikut (Karlis dan Xekalaki, 2000).

$$VT = \sum_{i=1}^{n} \frac{\left(y_i - \bar{y}\right)^2}{\bar{y}} = (n-1)\frac{s^2}{\bar{y}} \qquad (2.22)$$

Pengujian equidispersi dapat dilakukan dengan *software* R dengan mengunakan *package AER*. Pengujian ini merupakan implementasi uji disperse yang di kembangkan oleh Cameron dan Trivedi (1998). Hipotesis pada pengujian ini adalah.

$H_0 : Var(Y) = \mu_i$

$H_1 : Var(Y) = \mu_i + ag(.)$,

a adalah nilai koefisien yang diperkirakan oleh regresi OLS $T = \frac{1}{2}\sum_{i=1}^{n}\left[\left(Y_i - \hat{\mu}_i\right)^2 - Y_i\right]$, sedakngkan $g(.)$ adalah suatu fungsi tertentu.

2.6 *Multivariate Adaptive Regression Spline*

Multivariate Adaptive Regression Spline (MARS) termasuk pendekatan regresi nonparametrik, dimana digunakan apabila tidak terdapat informasi mengenai bentuk fungsi dan tidak jelasnya pola hubungan antara variabel prediktor dengan variabel respon

(Eubank, 1999). Kelebihan MARS adalah pada kemampuannya untuk memperkirakan konstribusi fungsi basis terhadap variabel respon, dengan tidak hanya dapat menangkap efek adaptif tetapi juga dapat menangkap efek interaksi antar prediktor *Generalized Cross Validation* (GCV) (Friedman, 1991). Metode MARS menjadi populer karena tidak mengasumsikan tipe khusus seperti hubungan (linier, kuadratik, dan kubik) diantara variabel prediktor dan respon, atau dengan kata lain hubungan variabel respon dan prediktor tidak diketahui. (Otok dkk, 2014).

Metode MARS merupakan kombinasi kompleks antara *truncated spline* dengan *Recursive Partitioning Regression* (RPR) (Friedman, 1991). Kelebihan MARS dibanding *truncated spline* dan RPR adalah sebagai berikut.

1. Metode MARS dapat digunakan pada pemodelan regresi yang melibatkan respon kontinu dan kategori, sedangkan *truncated spline* umumnya hanya digunakan pada respon kontinu saja.
2. Metode MARS mampu mengakomodir pengaruh aditif dan pengaruh interaksi antara prediktor dalam pemodelannya, sedangkan *truncated spline* hanya mengakomodir pengaruh aditif.
3. Jika dibandingkan dengan RPR yaitu MARS menghasilkan model yang kontinu pada knot, sedangkan pada RPR model yang kontinu pada knot tidak ditemui.
4. Sisi waktu komputasi untuk pemodelan MARS melibatkan banyak prediktor dibandingkan dengan *truncated spline*, karena pemilihan knot pada MARS dilakukan dengan prosedur adaptif yang meliputi *forward* dan *backward stepwise*.

Pemodelan MARS dilakukan dengan memperhatikan Basis Fungsi (BF), Maksimum Interaksi (MI), dan Minimum Observasi (MO) (Friedman, 1991). Definisi dari BF adalah suatu fungsi untuk menjelaskan hubungan antara variabel respon dengan variabel prediktor. Jumlah maksimum BF adalah dua sampai empat kali jumlah variabel prediktor. Definisi dari MI adalah banyaknya interaksi yang bisa terjadi pada model. Jumlah interaksi maksimum yaitu 1, 2, dan 3. Jika lebih dari tiga maka model yang dihasilkan

sangat kompleks sehingga sulit untuk diinterpretasikan. Definisi dari MO adalah jumlah pengamatan yang paling minimal antar knot. Jumlah MO yang digunakan adalah 0, 1, 2, dan 3.

Persamaan umum model MARS adalah sebagai berikut Friedman, 1991).

$$y_i = \alpha_0 + \sum_{m=1}^{M} \alpha_m B_m \left(x_i \right) + \varepsilon_i \qquad (2.23)$$

dimana α_0 adalah koefisien konstanta dari basis fungsi β_0, α_m adalah merupakan koefisien dari basis fungsi ke-*m*, serta $\beta_m(x) = \prod_{k=1}^{K_m}\left[S_{km}(x_{v(k,m)} - t_{km})\right]$, sehingga jika ditulis dalam matriks sebagai berikut.

$$\mathbf{y} = \mathbf{B}\boldsymbol{\alpha} + \boldsymbol{\varepsilon} \qquad (2.24)$$

Dimana nilai $\mathbf{y} = (y_1, y_2, ..., y_n)^T, \boldsymbol{\alpha} = (\alpha_0, \alpha_1, ..., \alpha_M)^T, \boldsymbol{\varepsilon} = (\varepsilon_1, \varepsilon_2, ..., \varepsilon_n)^T$ dimana *y* variabel respon yang berukuran $(n \times 1)$, $\boldsymbol{\alpha}$ merupakan vektor yang memuat koefisien regresi berukuran $((M+1)\times 1)$. $\boldsymbol{\varepsilon}$ merupakan vektor *random error* berukuran $(n \times 1)$, dan nilai $\boldsymbol{B}$ merupakan matriks berukuran $(n \times (M+1))$ sebagai berikut.

$$\mathbf{B} = \begin{bmatrix} 1 & \prod_{k=1}^{K_1}\left[s_{k1}\left(x_{v(k,1)1} - t_{k1} \right) \right]_+ & \cdots & \prod_{k=1}^{K_M}\left[s_{kM}\left(x_{v(k,\mathrm{M})1} - t_{kM} \right) \right]_+ \\ 1 & \prod_{k=1}^{K_1}\left[s_{k1}\left(x_{v(k,1)2} - t_{k1} \right) \right]_+ & \cdots & \prod_{k=1}^{K_M}\left[s_{kM}\left(x_{v(k,\mathrm{M})2} - t_{kM} \right) \right]_+ \\ \vdots & \vdots & \ddots & \vdots \\ 1 & \prod_{k=1}^{K_1}\left[s_{k1}\left(x_{v(k,1)\mathrm{n}} - t_{k1} \right) \right]_+ & \cdots & \prod_{k=1}^{K_M}\left[s_{kM}\left(x_{v(k,\mathrm{M})\mathrm{n}} - t_{kM} \right) \right]_+ \end{bmatrix} \qquad (2.25)$$

2.6.1 Penaksiran Parameter Model *Multivariate Adaptive Regression Spline* (MARS)

Estimator MARS menurut (Friedman, 1991) dinyatakan dalam persamaan (2.26).

$$\hat{f}(x_i) = \hat{\alpha}_0 + \sum_{m=1}^{M} \hat{\alpha}_m \prod_{k=1}^{K_m} \left[s_{km} \left(x_{v(k,m)\mathrm{i}} - t_{km} \right) \right]^{+} = \hat{\alpha}_0 + \sum_{m=1}^{M} \hat{\alpha}_m B_m(x_i) \tag{2.26}$$

dimana $B_{mi}(\mathbf{x}_i) = \prod_{k=1}^{K_m} \left[s_{km} \left(x_{v(k,m)\mathrm{i}} - t_{km} \right) \right]$, dengan $x_{v(k,m)\mathrm{i}} \in \left\{ x_j \right\}_{j=1}^{p}$ dan $t_{km} \in \left\{ x_{v(k,m)i} \right\}_{i=1}^{n}$

Apabila $s_{km} = +1$, maka

$$\left(x_{v(k,m)i} - t_{km} \right)^{+} = \begin{cases} x_{v(k,m)\mathrm{i}} - t_{km}, \, jika \, x_{v(k,m)\mathrm{i}} > t_{km}, dan \\ 0, lainnya \end{cases}$$

Apabila $s_{km} = -1$, maka

$$\left(x_{v(k,m)i} - t_{km} \right)^{+} = \begin{cases} t_{km} - x_{v(k,m)\mathrm{i}}, \, jika \, t_{km} > x_{v(k,m)\mathrm{i}}, dan \\ 0, lainnya \end{cases}$$

Persamaan $B_{mi}(\mathbf{x}_i)$ jika dinyatakan menjadi satu kesatuan.

$$B_{mi}(\mathbf{x}_i) = \left[\max(s_{km}(x_{v(k,m)\mathrm{i}} - t_{km}), 0) \right]_{+} \tag{2.27}$$

Keterangan :

$\hat{\alpha}_0$: parameter dugaan basis fungsi konstan.

$\hat{\alpha}_m$: parameter dugaan basis fungsi *nonconstant* ke-*m.*

M : banyaknya basis fungsi *nonconstant*.

K_m : maksimum interaksi pada fungsi basis ke-*m.*

S_{km} : tanda/sign fungsi basis, bernilai ± 1, bernilai +1 jika knot terletak disebelah kanan atau -1 jika knot terletak

disebelah kiri sub wilayah, merupakan fungsi basis interaksi ke-*k* dan fungsi basis ke-*m*.

$x_{v(\mathrm{k},m)i}$: variabel *x* ke-*v*, dimana *v* adalah indeks salah satu variabel *x* yang berkaitan dengan interaksi ke-*k* dan fungsi basis ke-*m* dalam fungsi MARS.

t_{km} : nilai knot pada interaksi ke-*k* dan fungsi basis ke-*m.*

$B_{mi}(\mathbf{x}_i)$: Fungsi basis ke-*m.*

2.6.2 Pengujian Parameter Model *Multivariate Adaptive Regression Spline* (MARS)

Pengujian parameter MARS secara serentak hipotesisnya adalah sebagai berikut.

$H_0 : \alpha_1 = ... = \alpha_M = 0$

H_1 : paling sedikit ada satu $\alpha_h \neq 0, \mathrm{h} = 1, ..., \mathrm{M}$

Statistik uji pengujian parameter MARS secara serentak adalah sebagai berikut (Agresti, 2002).

$$G^2 = -2\ln\Lambda = -2\ln\left\{\frac{L(\hat{\omega})}{L(\hat{\Omega})}\right\} = 2\left(\ln L(\hat{\Omega}) - \ln L(\hat{\omega})\right) \qquad (2.28)$$

Tolak H_0 jika $G^2 > \chi^2_{\alpha,\mathrm{v}}$ dimana $v = n(\Omega) - n(\omega)$.

Pengujian parameter MARS secara parsial hipotesisnya adalah sebagai berikut.

$H_0 : \alpha_h = 0$

$H_1 : \alpha_h \neq 0, \mathrm{h} = 1, ... \mathrm{M}$

Statistik uji pengujian parameter MARS secara parsial adalah sebagai berikut (Draper dan Smith, 1998).

$$t = \frac{\hat{\alpha}_h}{\mathrm{se}(\hat{\alpha}_h)} \qquad (2.29)$$

$$\text{se}(\hat{\alpha}_h) = \sqrt{\left(\frac{\sum_{i=1}^{n} (y_i - \hat{y}_i)^2}{n-k-1} \right) C_{hh}} \qquad (2.30)$$

dimana C_{hh} adalah elemen-elemen pada diagonal utama matriks $\left(\mathbf{B}^T\mathbf{B}\right)^{-1}$. Tolak H_0 jika $|t| > t_{(\alpha/2,v_2)}$ atau *P-value* < α, $v_2 = n-k$, k merupakan banyaknya fungsi basis yang berkontribusi terhadap model.

2.6.3 *Generalized Cross Validation* (GCV)

Tahap awal adalam MARS adalah menetukan titik knot (titik perubahan perilaku). Pemilihan knot pada MARS menggunakan algoritma *forward stepwise* dan *backward stepwise* dengan melihat nilai *Generalized Cross Validation* (GCV) terkecil (Friedman, 1991). Rumus GCV seperti pada persamaan (2.31) sebagai berikut (Friedman, 1991).

$$GCV(M) = \frac{MSE}{\left[1 - \frac{C(\tilde{\mathrm{M}})}{n}\right]^2} = \frac{\frac{1}{n}\sum_{i=1}^{n}\left[y_i - \hat{f}_M(\mathbf{x}_i)\right]^2}{\left[1 - \frac{C(\tilde{\mathrm{M}})}{n}\right]^2} \qquad (2.31)$$

dimana,

$$C(\tilde{\mathrm{M}}) = C(M) + d.\mathrm{M}\,,\ \hat{f}_M(\mathbf{x}_i) = \hat{\alpha}_0 + \sum_{m=1}^{M} \hat{\alpha}_m \prod_{k=1}^{K_m} \left[s_{km}\left(x_{v(k,m)\mathrm{i}} - t_{km} \right) \right]^{+}.$$

Keterangan masing-masing symbol adalah sebagai berikut.

n : Jumlah data

M : Jumlah fungsi basis pada MARS

$C(\tilde{\mathrm{M}})$: Fungsi kompleks

$C(\mathrm{M})$: $trace\left[\mathbf{B}(\mathbf{B}^T\mathbf{B})^{-1}\mathbf{B}^T\right]+1$

d : Derajat interaksi. Friedman (1991) menyarankan d=2 untuk model

aditif dan *d*=3 untuk model interaksi

y_i : Nilai variabel respon ke-*i*

$\hat{f}_M(\mathbf{x}_i)$: Nilai taksiran variabel respon pada fungsi basis *M*.

$$R^2 = 1 - \frac{SSE}{SST} = 1 - \frac{\sum_{i=1}^{n}\left[y_i - \hat{y}_i\right]^2}{\sum_{i=1}^{n}\left[y_i - \bar{y}_i\right]^2} \text{ (Draper dan Smith, 1998)} \quad (2.32)$$

Model terbaik MARS adalah model dengan nilai GCV terkecil dan nilai R^2 terbesar.

Analisis kepentingan variable di perlukan untuk memaksimalkan sistem penyeleksian. Analisis ini dapat digunakan apabila variabel prediktor lebih dari satu. Nilai kepentingan variabel prediktor pada *package* R *earth* mengacu pada tiga kriteria, yaitu *nsubset*, GCV, dan RSS. *nsubset* adalah ketika variabel yang banyak berkontribusi pada suatu himpunan maka akan lebih penting. Berdasarkan GCV dan RSS, variabel yang paling penting adalah variabel yang paling banyak manyebabkan GCV dan RSS menurun.

2.7 Koefisien Korelasi

Koefisien korelasi berguna untuk mngetahui hubungan linier antara dua variabel, dimana rentangnya $-1 \le r_{xy} \le 1$. Dua variabel dikatakan memiliki hubungan apa bila nilai koefisien korelasi mendekati 1 atau -1, sedangkan tidak memiliki hubungan apabila nilainya mendekati 0. Rumus koefisien korelasi Spearman adalah sebagai berikut (Hogg, McKean, dan Craig, 2019)

$$r_{xy} = \frac{\sum_{i=1}^{n}\left(x_i - \bar{x}\right)\left(y_i - \bar{y}\right)}{\sqrt{\left(\sum_{i=1}^{n}\left(x_i - \bar{x}\right)^2\right)}\sqrt{\left(\sum_{i=1}^{n}\left(y_i - \bar{y}\right)^2\right)}} \quad (2.33)$$

Pengujian korelasi antar variabel, hipotesisnya sebagai berikut.

$H_0 : \rho_{x,y} = 0$ (tidak terdapat hubungan antar variabel)

$H_1 : \rho_{x,y} \neq 0$ (terdapat hubungan antar variabel)

Statistik uji pengujian korelasi antar variabel adalah sebagai berikut (Gujarati, 2003).

$$t = \frac{r_{x,y}\sqrt{n-2}}{\sqrt{1-\left(r_{x,y}\right)^2}} \tag{2.34}$$

Tolak H_0 jika $|t| > t_{(\alpha/2,(n-2))}$.

2.8 *Multivariate Adaptive Generalized Poisson Regression Spline* (MAGPRS)

Subbab ini akan membahas tentang penaksiran parameter MAGPRS dan tahapan untuk mendapatkan penaksiran parameter, serta pengujian parameter MAGPRS dan tahapan mendapatkan pengujian parameter berdasarkan penelitian oleh Hidayati, Otok, dan Purhadi (2019). Model MAGPRS adalah metode pengembangan dari MARS. Model ini menggabungkan *Generalized Poisson Regression* dengan MARS. Model MAGPRS dituliskan seperti berikut ini.

$$Y_i \sim GP\left(u_i, \theta\right)$$

$$\begin{aligned} \ln \mu_i = f(\mathbf{x}_i) &= \alpha_0 + \sum_{m=1}^{M} \alpha_m \prod_{k=1}^{K_m} \left[s_{km} \left(x_{v(k,m)\mathrm{i}} - t_{km} \right) \right]_+ \\ &= \alpha_0 + \sum_{m=1}^{M} \alpha_m B_{mi}\left(\mathbf{x}_i\right) \end{aligned} \tag{2.35}$$

$$\mu = \exp\left(\alpha_0 + \sum_{m=1}^{M} \alpha_m B_{mi}\left(\mathbf{x}_i\right) \right) = \exp(\mathbf{B\alpha})$$

2.8.1 Penaksiran Parameter Model *Multivariate Adaptive Generalized Poisson Regression Spline* (MAGPRS)

Subbab ini akan membahas penaksiran perameter MAGPRS dan tahapan untuk mendapatkan penaksiran parameter berdasarkan penelitian oleh Hidayati, Otok, dan Purhadi (2019). Penaksiran parameter pada model MAGPRS menggunakan *Weighted Least Square* (WLS). $\boldsymbol{\alpha} = (\alpha_0, \alpha_1, ..., \alpha_m)^T$ adalah parameter yang diduga. $f(\mathbf{x}_i)$ adalah hubungan antara variabel $\mathbf{X}$ dan $\mathbf{y}$ dinyatakan dalam fungsi regresi (Friedman, 1991), sehingga dapat dituliskan sebagai berikut.

$$\begin{aligned} f(\mathbf{x}_i) &= \alpha_0 + \sum_{m=1}^{M} \alpha_m \prod_{k=1}^{K_m} \left[s_{km} \left(x_{v(k,m)\mathrm{i}} - t_{km} \right) \right]_+ \\ &= \alpha_0 + \sum_{m=1}^{M} \alpha_m \left[s_{1m} (x_{\mathrm{v}(1,m)\mathrm{i}} - t_{1m}) \right] + \sum_{m=1}^{M} \alpha_m \left[s_{1m} (x_{\mathrm{v}(1,m)\mathrm{i}} - t_{1m}) \right] \\ &\quad \left[s_{2m} (x_{\mathrm{v}(2,m)\mathrm{i}} - t_{2m}) \right] + \sum_{m=1}^{M} \alpha_m \left[s_{1m} (x_{\mathrm{v}(1,m)\mathrm{i}} - t_{1m}) \right] \\ &\quad \left[s_{2m} (x_{\mathrm{v}(2,m)\mathrm{i}} - t_{2m}) \right] \left[s_{3m} (x_{\mathrm{v}(3,m)\mathrm{i}} - t_{3m}) \right] + ... \end{aligned} \tag{2.36}$$

Persamaan 2.37 jika dibuat bentuk umumnya sebagai berikut :

$$\begin{aligned} f(\mathbf{x}_i) &= \alpha_0 + \sum_{K_m=1} f_i(\mathbf{x}_i) + \sum_{K_m=2} f_{ij}(\mathbf{x}_i, \mathbf{x}_j) \\ &\quad + \sum_{K_m=3} f_{ijl}(\mathbf{x}_i, \mathbf{x}_j, \mathbf{x}_l) + ... \end{aligned} \tag{2.37}$$

Indeks *i*, *j*, *k* pada persamaan (2.37) menunjukkan variabel. Penjumlahan pertama pada persamaan (2.37) merupakan penjumlahan semua fungsi untuk satu variabel, penjumlahan kedua adalah penjumlahan semua fungsi untuk interaksi dua variabel, penjumlahn ketiga adalah penjumlahan semua fungsi untuk interaksi tiga variabel.

Jika dimisalkan $V(m)=\{v(k,m)\}_1^{K_m}$ adalah himpunan dari indeks variabel yang ada dalam fungsi basis ke-m B_{mi}, maka penjumlahan pertama dalam persamaan (2.37) mempunyai fungsi univariat seperti pada persamaan (2.38).

$$f_i(\mathbf{x}_i)=\sum_{\substack{K_m=1\\ i\in V(m)}} \alpha_m B_{mi}(\mathbf{x}_i)=\sum_{m=1}^{M}\alpha_m\left[s_{1m}\left(x_{v(1,m)i}-t_{1m}\right)\right] \tag{2.38}$$

dimana $f_i(\mathbf{x}_i)$ adalah penjumlahan dari semua fungsi basis untuk variabel x_i saja, dimana menyatakan fungsi dari satu variabel saja. Penjumlahan kedua pada persamaan (2.37), yang adalah fungsi basis untuk interaksi dua variabel dinyatakan sebagai berikut.

$$\begin{aligned} f_{ij}(\mathbf{x}_i,\mathbf{x}_j) &= \sum_{\substack{K_m=2\\ (i,j)\in V(m)}} \alpha_m B_{mi}(\mathbf{x}_i,\mathbf{x}_j) \\ &= \sum_{m=1}^{M}\alpha_m\left[s_{1m}(x_{\mathrm{v}(1,m)\mathrm{i}}-t_{1m})\right]\left[s_{2m}(x_{\mathrm{v}(2,m)\mathrm{i}}-t_{2m})\right] \end{aligned} \tag{2.39}$$

$f_{ij}(\mathbf{x}_i,\mathbf{x}_j)$ adalah penjumlahan semua fungsi basis untuk interaksi dua variabel, yaitu x_i dan x_j. Penambahan fungsi (2.39) dengan fungsi univariat pada persamaan (2.38) menghasilkan

$$f_{ij}^{*}(\mathbf{x}_i,\mathbf{x}_j)=f_i(\mathbf{x}_i)+f_j(\mathbf{x}_j)+f_{ij}(\mathbf{x}_i,\mathbf{x}_j) \tag{2.40}$$

Persamaan (2.40) menyatakan fungsi dari dua variabel x_i dan x_j baik fungsi univariat maupun fungsi interaksi antar variabel. Fungsi trivariat pada persamaan (2.40) dan penjumlahan ketiga dalam persamaan (2.37) dapat dinyatakan sebagai

$$f_{ijl}\left(\mathbf{x}_i,\mathbf{x}_j,\mathbf{x}_l\right)=\sum_{\substack{K_m=3\\(i,j,l)\in V(m)}}\alpha_m B_{mi}\left(\mathbf{x}_i,\mathbf{x}_j,\mathbf{x}_l\right)$$

$$=\sum_{m=1}^{M}\alpha_m\left[s_{1m}(x_{\mathrm{v}(1,m)\mathrm{i}}-t_{1m})\right]\left[s_{2m}(x_{\mathrm{v}(2,m)\mathrm{i}}-t_{2m})\right]$$

$$\left[s_{3m}(x_{\mathrm{v}(3,m)\mathrm{i}}-t_{3m})\right] \qquad (2.41)$$

$f_{ijl}\left(\mathbf{x}_i,\mathbf{x}_j,\mathbf{x}_l\right)$ adalah penjumlahan semua fungsi basis untuk interaksi tiga variabel x_i , x_j , x_l . Penambahan fungsi (2.41) dengan fungsi (2.39) dan fungsi univariat (2.38) seperti pada persamaan berikut.

$$f_{ijl}^{\ *}\left(\mathbf{x}_i,\mathbf{x}_j,\mathbf{x}_l\right)=f_i\left(\mathbf{x}_i\right)+f_j\left(\mathbf{x}_j\right)+f_l\left(\mathbf{x}_l\right)+f_{ij}\left(\mathbf{x}_i,\mathbf{x}_j\right)$$
$$+f_{il}\left(\mathbf{x}_i,\mathbf{x}_l\right)+f_{jl}\left(\mathbf{x}_j,\mathbf{x}_l\right)+f_{ijl}\left(\mathbf{x}_i,\mathbf{x}_j,\mathbf{x}_l\right) \qquad (2.42)$$

Fungsi pada persamaan (2.42) merupakan gambaran dari kontribusi trivariat secara bersama. Variabel-variabel yang saling berinteraksi adalah variabel prediktor x_i , x_j , x_l .

Hubungan antara variabel $\mathbf{x}$ dan $\mathbf{y}$ dinyatakan dalam fungsi regresi $f\left(\mathbf{x}_i\right)$, dimana tidak diketahui bentuk fungsinya dan diasumsikan mengikuti model regresi nonparametrik, maka dapat dinyatakan dalam bentuk persamaan regresi sebagai berikut.

$$y_i = f\left(x_{1i},x_{2i},\ldots,x_{pi}\right)+\varepsilon_i \ ;i=1,2,\ldots,n$$

$$=\alpha_0+\sum_{m=1}^{M}\alpha_m B_{mi}(\mathbf{x}_i)+\varepsilon_i \qquad (2.43)$$

Jika persamaan (2.43) ditulis dalam bentuk matriks akan sesuai dengan persamaan (2.25) dan (2.26).

Nilai estimasi model MAGPRS dapat diperoleh dengan menggunakan metode *Weighted Least Square* (WLS). Tahapan untuk mendapatkan estimator MAGPRS dimulai dengan memisalkan distribusi probabilitas untuk setiap $Y_i \sim GP(\mu_i,\theta)$,

$i = 1,2,...,n$ dengan distribusi *generalized poisson* adalah sebagai berikut (Famoye, Wulu, dan Sigh, 2004).

$$f(y_i \mid \mu_i, \theta) = \left(\frac{\mu}{1+\theta\mu}\right)^{y_i} \frac{(1+\theta y_i)^{y_i-1}}{y_i!} \exp\left(\frac{-\mu(1+\theta y_i)}{1+\theta\mu}\right); y_i = 0,1,2,... \quad (2.44)$$

Diperlukan fungsi distribusi *generalized poisson* pada persamaan (2.44) yang masuk dalam keluarga eksponensial. Fungsi keluarga eksponensial terlihat pada persamaan (2.45) berikut.

$$P(y|\eta) = h(y)\exp\left\{\eta^T T(y) - A(\eta)\right\} \quad (2.45)$$

dimana η adalah natural parameter, $T(y)$ adalah *sufficient statistics*, dan $A(\eta)$ adalah fungsi partisi log. Pembuktian bahwa distribusi *Generalized Poisson* termasuk kedalam keluarga eksponensial adalah sebagai berikut.

$$P(y|\eta) = \exp\left\{\log\left(\left(\frac{\mu}{1+\theta\mu}\right)^{y} \frac{(1+\theta x)^{y-1}}{\text{y!}} \exp\left(\frac{-\mu(1+\theta y)}{1+\theta y}\right)\right)\right\} \quad (2.46)$$

$$P(y|\eta) = \frac{1}{\text{y!}} \frac{(1+\theta y)^{y-1}}{(1+\theta\mu)^{y}} \exp\left\{\text{y}\log\mu - \frac{\mu(1+\theta y)}{1+\theta y}\right\} \quad (2.47)$$

Persamaan (2.47) di atas adalah persamaan keluarga eksponensial dengan $\eta = \log\mu$, $T(y) = y$, dan $\mu = \exp\{\eta\}$. Terbukti bahwa distribusi *generalized poisson* $Y_i \sim GP(\mu_i, \theta)$ termasuk dalam keluarga eksponensial, karena persamaan (2.47) mempunyai bentuk sama dengan persamaan (2.45), dimana *link function* nya sebagai berikut:

$$\mu = \exp(\eta), \text{ sehingga } \eta = \log(\mu) \quad (2.48)$$

Sehingga model MAGPRS sebagai berikut.

$$\mu = \exp\{\eta\}$$

$$\mu_i = \exp\left(\alpha_0 + \alpha_1 \prod_{k=1}^{K_1} \left[s_{k1} \left(x_{v(k,1)\mathrm{i}} - t_{k1} \right) \right]^+ + ... \right. \qquad (2.49)$$

$$\left. + \alpha_M \prod_{k=1}^{K_M} \left[s_{kM} \left(x_{v(k,\mathrm{M})\mathrm{i}} - t_{kM} \right) \right]^+ \right)$$

$$\mu_i = \exp\left(\alpha_0 + \sum_{m=1}^{M} \alpha_m B_{mi}\left(\mathbf{x}_i\right) \right)$$

$$\mu_i = \exp\left(\mathbf{B\alpha}\right)$$

$$\ln(\mu_i) = \mathbf{B\alpha}$$

dimana penjabaran **B** dapat dilihat pada persamaan (2.25).

Estimasi parameter MAGPRS menggunakan WLS, dimana erornya adalah $\varepsilon = Y - E\left(Y\right) = Y - \mu = Y - \exp\left(\mathbf{B\alpha}\right) = \ln\left(Y\right) - \left(\mathbf{B\alpha}\right)$ menggunakan asumsi pembobot varians dari *Y* berupa matriks **W** Matriks **W** merupakan matriks diagonal pembobot berukuran $n \times n$ dengan elemen diagonalnya $\frac{1}{w_i}$, dimana $\frac{1}{w_i} = \frac{1}{\mu_i \left(1 + \theta\mu_i\right)^2}$ dan *n* adalah banyaknya observasi.

$$\mathbf{W} = \begin{bmatrix} \frac{1}{w_1} & 0 & 0 & 0 \\ 0 & \frac{1}{w_2} & 0 & 0 \\ 0 & 0 & \ddots & 0 \\ 0 & 0 & 0 & \frac{1}{w_n} \end{bmatrix} = \begin{bmatrix} \frac{1}{\mu_1\left(1+\theta\mu_1\right)^2} & 0 & 0 & 0 \\ 0 & \frac{1}{\mu_2\left(1+\theta\mu_2\right)^2} & 0 & 0 \\ 0 & 0 & \ddots & 0 \\ 0 & 0 & 0 & \frac{1}{\mu_n\left(1+\theta\mu_n\right)^2} \end{bmatrix} \qquad (2.50)$$

sehingga estimasi parameter MAGPRS menggunakan WLS, dengan meminimumkan jumlah kuadrat *error* (Friedman, 1991) sebagai berikut:

$$\psi = \boldsymbol{\varepsilon}^T \mathbf{W} \boldsymbol{\varepsilon} = \left(\mathbf{y} - \mathbf{B}\boldsymbol{\alpha}\right)^T \mathbf{W}\left(\mathbf{y} - \mathbf{B}\boldsymbol{\alpha}\right) \tag{2.51}$$

dimana fungsi ψ yang merupakan jumlah kuadrat *error* persamaan (2.51) di atas dapat dibentuk sebagai berikut:

$$\begin{aligned} \psi &= \boldsymbol{\varepsilon}^T \mathbf{W} \boldsymbol{\varepsilon} = \left(\mathbf{y} - \mathbf{B}\boldsymbol{\alpha}\right)^T \mathbf{W}\left(\mathbf{y} - \mathbf{B}\boldsymbol{\alpha}\right) \\ \psi &= \mathbf{y}^T \mathbf{W}\mathbf{y} - \mathbf{y}^T \mathbf{W}\mathbf{B}\boldsymbol{\alpha} - \mathbf{B}^T \boldsymbol{\alpha}^T \mathbf{W}\mathbf{y} + \mathbf{B}^T \boldsymbol{\alpha}^T \mathbf{W}\mathbf{B}\boldsymbol{\alpha} \end{aligned} \tag{2.52}$$

yang dapat diminimumkan persamaan (2.52) dengan mencari turunan parsial pertama dari fungsi ψ terhadap $\boldsymbol{\alpha}$ dan menyatakan dengan nol,

$$\frac{\partial \psi}{\partial \boldsymbol{\alpha}} = \frac{\partial\left(\mathbf{y}^T \mathbf{W}\mathbf{y} - \mathbf{y}^T \mathbf{W}\mathbf{B}\boldsymbol{\alpha} - \mathbf{B}^T \boldsymbol{\alpha}^T \mathbf{W}\mathbf{y} + \mathbf{B}^T \boldsymbol{\alpha}^T \mathbf{W}\mathbf{B}\boldsymbol{\alpha}\right)}{\partial \boldsymbol{\alpha}} = 0$$

$$\frac{\partial \psi}{\partial \boldsymbol{\alpha}} = -2\mathbf{y}^T \mathbf{W}\mathbf{B} + 2\boldsymbol{\alpha}\mathbf{B}^T \mathbf{W}\mathbf{B} = 0$$

dari hasil persamaan turunan (2.53) diperoleh hasil sebagai berikut:

$$\mathbf{B}^T \mathbf{W}\mathbf{B}\boldsymbol{\alpha} = \mathbf{y}\mathbf{W}\mathbf{B} \tag{2.53}$$

dengan mengalikan kedua ruas pada persamaan (2.53) dikalikan dengan $\left(\mathbf{B}^T \mathbf{W}\mathbf{B}\right)^{-1}$, sehingga diperoleh estimasi parameter MAGPRS untuk $\boldsymbol{\alpha}$.

$$\hat{\boldsymbol{\alpha}}_{WLS} = \left(\mathbf{B}^T \mathbf{W}\mathbf{B}\right)^{-1} \mathbf{W}\mathbf{B}\mathbf{y} \tag{2.54}$$

Estimasi model MAGPRS sebagai berikut (Otok, Hidayati, dan Purhadi, 2019).

$$\hat{f}\left(\mathbf{x}\right) = \ln(\hat{\mu}) = \mathbf{B}\hat{\boldsymbol{\alpha}} = \mathbf{B}\left(\mathbf{B}^T \mathbf{W}\mathbf{B}\right)^{-1} \mathbf{W}\mathbf{B}\mathbf{y} \tag{2.55}$$

2.8.2 Pengujian Parameter Model *Multivariate Adaptive Generalized Poisson Regression Spline* (MAGPRS)

Pengujian serentak MAGPRS menggunakan metode *Maximum Likelihood Ratio Test* (MLRT), dan pengujian parameter secara parsial menggunakan statistik uji T. Hipotesis pengujian serentak adalah sebagai berikut.

$H_0 : \alpha_1 = ... = \alpha_M = 0$

$H_1 :$ paling sedikit ada satu $\alpha_m \neq 0, \mathrm{m} = 1, ..., \mathrm{M}$

Tahapan yang dilakukan adalah menentukan himpunan parameter dibawah populasi $\Omega = \{\theta, \alpha_1, ..., \alpha_m\}$ dan himpunan parameter dibawah H_0 yaitu $\omega = \{\theta\}$. Fungsi likelihood himpunan parameter dibawah populasi sebagai berikut:

$$f\left(y_i \middle| \Omega\right) = \left(\frac{\mu_i}{1+\theta\mu_i}\right)^{y_i} \frac{\left(1+\theta y_i\right)^{y_i - 1}}{y_i !} \exp\left(\frac{-\mu_i\left(1+\theta y_i\right)}{1+\theta\mu_i}\right)$$

$y_i = 0, 1, 2, , ...$

$$L(\Omega) = \prod_{i=1}^{n} f\left(y_i \middle| \Omega\right)$$

$$= \prod_{i=1}^{n}\left(\frac{\mu_i}{1+\theta\mu_i}\right)^{y_i} \prod_{i=1}^{n} \frac{\left(1+\theta y_i\right)^{y_i - 1}}{y_i !} \exp\left(\sum_{i=1}^{n} \frac{-\mu_i\left(1+\theta y_i\right)}{1+\theta\mu_i}\right)$$

$$= \prod_{i=1}^{n}\left(\frac{\exp\left(\mathbf{B\alpha}\right)}{1+\theta\exp\left(\mathbf{B\alpha}\right)}\right)^{y_i} \prod_{i=1}^{n} \frac{\left(1+\theta y_i\right)^{y_i - 1}}{y_i !} \qquad (2.56)$$

$$\exp\left(\sum_{i=1}^{n} \frac{\left(\exp\left(\mathbf{B\alpha}\right)\right)\left(1+\theta y_i\right)}{1+\theta\left(\exp\left(\mathbf{B\alpha}\right)\right)}\right)$$

dimana $\mu_i = \exp\left(\alpha_0 + \sum_{m=1}^{M} \alpha_m B_{mi}(\mathbf{x}_i)\right) = \exp\left(\mathbf{B\alpha}\right)$. Selanjutnya, maksimumkan logaritma natural fungsi *likelihood* di bawah populasi, $L\left(\hat{\Omega}\right)$ sebagai berikut.

$$\ln L(\Omega) = \sum_{i=1}^{n} \ln\left[\left(\frac{\exp\left(\mathbf{B\alpha}\right)}{1+\theta\exp\left(\mathbf{B\alpha}\right)}\right)^{y_i} \frac{\left(1+\theta y_i\right)^{y_i - 1}}{y_i !}\right.$$

$$\left.\exp\left(\sum_{i=1}^{n} \frac{\left(\exp\left(\mathbf{B\alpha}\right)\right)\left(1+\theta y_i\right)}{1+\theta\exp\left(\mathbf{B\alpha}\right)}\right)\right]$$

$$= \sum_{i=1}^{n} \left\{ y_i \left(\mathbf{B}\boldsymbol{\alpha}\right) - y_i \ln\left(1+\theta\exp\left(\mathbf{B}\boldsymbol{\alpha}\right)\right) + \left(y_i - 1\right)\ln\left(1+\theta y_i\right) \right.$$

$$\left. - \ln\left(y_i !\right) - \exp\left(\mathbf{B}\boldsymbol{\alpha}\right)\left(1+\theta y_i\right)\left(1+\theta\exp\left(\mathbf{B}\boldsymbol{\alpha}\right)\right)^{-1} \right\} \qquad (2.57)$$

Estimasi parameter didapatkan dengan menurunan persamaan (2.57) terhadap $\left(\boldsymbol{\alpha}, \theta\right)$. Turunan persamaan (2.57) terhadap $\boldsymbol{\alpha}$ sebagai berikut,

$$\frac{\partial \ln \mathrm{L}\left(\Omega\right)}{\partial \boldsymbol{\alpha}} = \sum_{i=1}^{n} \left[\left(y_i \mathbf{B} - \left(\theta\, y_i \mathbf{B} \exp\left(\mathbf{B}\boldsymbol{\alpha}\right) / 1+\theta\exp\left(\mathbf{B}\boldsymbol{\alpha}\right)\right)\right) \right.$$

$$- \left(1+\theta y_i\right) \left\{ \left[\left(\mathbf{B}\exp\left(\mathbf{B}\boldsymbol{\alpha}\right)\right) / \left(1+\theta\exp\left(\mathbf{B}\boldsymbol{\alpha}\right)\right) \right] \right.$$

$$\left. \left. - \left[\theta \mathbf{B} \left(\exp\left(\mathbf{B}\boldsymbol{\alpha}\right)\right)^2 / \left(1+\theta\exp\left(\mathbf{B}\boldsymbol{\alpha}\right)\right)^2 \right] \right\} \right] \qquad (2.58)$$

Turunan pertama persamaan (2.57) terhadap $\left(\theta\right)$ sebagai berikut

$$\frac{\partial \ln \mathrm{L}\left(\Omega\right)}{\partial \theta} = \sum_{i=1}^{n} \left\{ y_i \exp\left(\mathbf{B}\boldsymbol{\alpha}\right)\left(1+\theta\exp\left(\mathbf{B}\boldsymbol{\alpha}\right)\right)^{-1} \right.$$

$$+ y_i \left(y_i - 1\right)\left(1+\theta y_i\right)^{-1} - \exp\left(\mathbf{B}\boldsymbol{\alpha}\right) \left[y_i \left(1+\theta\exp\left(\mathbf{B}\boldsymbol{\alpha}\right)\right)^{-1} \right.$$

$$\left. \left. - \left(1+\theta y_i\right)\exp\left(\mathbf{B}\boldsymbol{\alpha}\right)\left(1+\theta\exp\left(\mathbf{B}\boldsymbol{\alpha}\right)\right)^{-2} \right] \right\} \qquad (2.59)$$

Fungsi *likelihood* di bawah H_0 adalah $L\left(\hat{\omega}\right)$ sebagai berikut, dimana $\mu_i = \exp\left(\alpha_0\right)$

$$f\left(y_i \middle| \omega\right) = \left(\frac{\mu_i}{1+\theta\mu_i} \right)^{y_i} \frac{\left(1+\theta y_i\right)^{y_i - 1}}{y_i !} \exp\left(\frac{-\mu_i \left(1+\theta y_i\right)}{1+\theta\mu_i} \right); y_i = 0,1,2,,...$$

$$L(\omega)=\prod_{i=1}^{n} f\left(y_i|\omega\right)$$

$$L(\omega)=\prod_{i=1}^{n}\left(\frac{\exp(\alpha_0)}{1+\theta\exp(\alpha_0)}\right)^{y_i}\prod_{i=1}^{n}\frac{(1+\theta y_i)^{y_i-1}}{y_i!} \qquad (2.60)$$

$$\exp\left(\sum_{i=1}^{n}\frac{(\exp(\alpha_0))(1+\theta y_i)}{1+\theta\exp(\alpha_0)}\right)$$

Selanjutnya, memaksimumkan logaritma natural fungsi *likelihood* di bawah H_0, $L(\hat{\omega})$ sebagai berikut.

$$\ln L(\omega)=\sum_{i=1}^{n}\ln\left[\left(\frac{\exp(\alpha_0)}{1+\theta\exp(\alpha_0)}\right)^{y_i}\frac{(1+\theta y_i)^{y_i-1}}{y_i!}\exp\left(\sum_{i=1}^{n}\frac{(\exp(\alpha_0))(1+\theta y_i)}{1+\theta\exp(\alpha_0)}\right)\right]$$

$$=\sum_{i=1}^{n}\left\{y_i\ln(\hat{\alpha}_0)-y_i\ln\left(1+\theta\exp(\hat{\alpha}_0)\right)+(y_i-1)\ln(1+\theta y_i)\right.$$

$$\left.-\ln(y_i!)-\exp(\hat{\alpha}_0)(1+\theta y_i)\left(1+\theta\exp(\hat{\alpha}_0)\right)^{-1}\right\} \qquad (2.61)$$

Estimasi parameter, maka dilakukan dengan menurunkan persamaan (2.61) terhadap θ. Sehingga diperoleh hasil sebagai berikut

$$\frac{\partial \ln L(\omega)}{\partial\theta}=\sum_{i=1}^{n}\left\{y_i\exp(\hat{\alpha}_0)\left(1+\theta\exp(\hat{\alpha}_0)\right)^{-1}+y_i(y_i-1)(1+\theta y_i)^{-1}\right.$$

$$\left.-\exp\hat{\alpha}_0\left[y_i\left(1+\theta\exp(\hat{\alpha}_0)\right)^{-1}-(1+\theta y_i)\exp(\hat{\alpha}_0)\left(1+\theta\exp(\hat{\alpha}_0)\right)^{-2}\right]\right\} \qquad (2.62)$$

Hasil penurunan pertama fungsi ln *likelihood* menunjukkan bahwa masih megandung parameter, sehingga fungsi tidak *close*

form, maka dari itu diperlukan proses selanjutnya untuk mendapatkan nilai parameter digunakan optimasi numerik. Optimasi numerik pada penelitian ini menggunakan algoritma Bernt-Hal-Hall-Hausman (BHHH). Algoritma BHHH untuk himpunan parameter di bawah populasi, berikut merupakan algoritma iterasi BHHH untuk himpunan parameter di bawah H_0.

1. Menentukan nilai awal γ_0 dan m=0 dengan nilai $\varepsilon > 0$ untuk batas toleransi konvergensi. $\gamma_o = \left[\hat{\theta}_0 \right]^T$ dimana nilai $\hat{\theta}_0 > 0$ sesuai dengan fungsi *generalized poisson*.
2. Membentuk vektor gradien, sebagai berikut.
$$\mathbf{g}\left(\hat{\gamma}_m\right) = \left[\frac{\partial L(\bullet)}{\partial \theta} \right]^T$$
3. Mencari turunan pertama fungsi ln *densitas* terhadap parameter
$$\mathbf{k}_i\left(\hat{\gamma}_m\right) = \left[\frac{\partial \ln f\left(y_i\right)}{\partial \theta} \right]^T$$
4. Membuat matrik Hessian, sebagai berikut
$$\mathbf{H}\left(\hat{\gamma}_m\right) = -\sum_{i=1}^{n} \mathbf{k}_i\left(\hat{\gamma}_m\right)\mathbf{k}_i\left(\hat{\gamma}_m\right)^T$$
5. Mensubtitusikan nilai $\hat{\gamma}_m$ pada elemen $\mathbf{g}\left(\hat{\gamma}_m\right)$ dan matriks Hessian $\mathbf{H}\left(\hat{\gamma}_m\right)$
6. Melakukan iterasi mulai m=0 dengan persamaan $\gamma_{m+1} = \gamma_m - \mathbf{H}^{-1}\left(\hat{\gamma}_m\right) g\left(\hat{\gamma}_m\right)$, iterasi berhenti jika $\left\|\hat{\gamma}_{m+1} - \hat{\gamma}_m\right\| \le \varepsilon$ dimana ε adalah bilangan positif yang sangat kecil mendekati nilai 0,001.
7. Mengulangi step (2) dan seterusnya dengan *m=m+1*

Nilai estimasi parameter dibawah populasi dan dibawah H_0 sudah didapatkan, selanjutnya menghitung statistik uji dengan menggunakan rumus sebagai berikut (Agresti, 2002).

$$G^2 = -2\ln\Lambda = -2\ln\left\{\frac{L(\hat{\omega})}{L(\hat{\Omega})}\right\} = -2ln\left(L(\hat{\omega}) - L(\hat{\Omega})\right)$$

$$= 2\left(\ln L(\hat{\Omega}) - \ln L(\hat{\omega})\right)$$

dimana

$$L(\hat{\Omega}) = \max_{\Omega} L(\Omega)$$

$$\ln L(\hat{\Omega}) = \sum_{i=1}^{n}\left\{y_i(\mathbf{B}\hat{\boldsymbol{\alpha}}) - y_i \ln\left(1+\hat{\theta}\exp(\mathbf{B}\hat{\boldsymbol{\alpha}})\right) + (y_i - 1)\ln\left(1+\hat{\theta}y_i\right)\right.$$

$$\left. -\ln(y_i!) - \exp(\mathbf{B}\hat{\boldsymbol{\alpha}})\left(1+\hat{\theta}y_i\right)\left(1+\hat{\theta}\exp(\mathbf{B}\hat{\boldsymbol{\alpha}})\right)^{-1}\right\}$$

$$L(\hat{\omega}) = \max_{\omega} L(\omega)$$

$$\ln L(\hat{\omega}) = \sum_{i=1}^{n}\left\{y_i \ln(\hat{\alpha}_0) - y_i \ln\left(1+\hat{\theta}\exp(\hat{\alpha}_0)\right) + (y_i - 1)\ln\left(1+\hat{\theta}y_i\right)\right.$$

$$\left. -\ln(y_i!) - \exp(\hat{\alpha}_0)\left(1+\hat{\theta}y_i\right)\left(1+\hat{\theta}\exp(\hat{\alpha}_0)\right)^{-1}\right\}$$

sehingga diperoleh hasil sebagai berikut (Hidayati, Otok, dan Purhadi, 2019).

$$\hat{G}^2 = -2\ln\Lambda = 2\left(\ln L(\hat{\Omega}) - \ln L(\hat{\omega})\right)$$

$$= 2\left[\sum_{i=1}^{n} y_i(\mathbf{B}\hat{\boldsymbol{\alpha}}) - \sum_{i=1}^{n} y_i \ln(\hat{\alpha}_0) + \sum_{i=1}^{n} y_i \frac{\ln\left(1+\hat{\theta}\exp(\hat{\alpha}_0)\right)}{\ln\left(1+\hat{\theta}\exp(\mathbf{B}\hat{\boldsymbol{\alpha}})\right)}\right.$$

$$-\sum_{i=1}^{n}\exp(\mathbf{B}\hat{\boldsymbol{\alpha}})\left(1+\hat{\theta}y_i\right)\left(1+\hat{\theta}\exp(\mathbf{B}\hat{\boldsymbol{\alpha}})\right)^{-1} \qquad (2.63)$$

$$\left. +\sum_{i=1}^{n}\exp(\hat{\alpha}_0)\left(1+\hat{\theta}y_i\right)\left(1+\hat{\theta}\exp(\hat{\alpha}_0)\right)^{-1}\right]$$

$\hat{G}^2$ bedistribusi χ^2, sehingga $\hat{G}^2 \sim \chi^2_{\alpha,v}$ dimana $v = n(\Omega) - n(\omega)$. Daerah penolakan dari hasil parameter yang diperoleh merupakan suatu nilai *ln likelihood* dibawah H_0 dan populasi. Tolak H_0 jika $\hat{G}^2 \sim \chi^2_{\alpha,v}$. Jika H_0 ditolak pada pengujian serentak, maka langkah selanjutnya adalah melakukan pengujian parameter secara parsial.

Pengujian secara parsial dilakuakn untuk mengetahui variabel prediktor mana yang mempunyai pengaruh signifikan terhadap variabel respon pada fungsi basis didalam model. Hipotesis pengujian secara individu atau parsial adalah sebagai berikut.

$H_0 : \alpha_m = 0$

$H_1 : \alpha_m \neq 0, \mathrm{m} = 1, ..., \mathrm{M}$

Statistik Uji :

$$z = \frac{\hat{\alpha}_m}{\mathrm{se}(\hat{\alpha}_m)}$$

dimana,

$$\mathrm{se}(\hat{\alpha}_m) = \sqrt{\left(\frac{\sum_{i=1}^{n} \left(y_i - \hat{y}_i \right)^2}{n-k-1} \right) C_{mm}}$$

C_{mm} adalah elemen-elemen pada diagonal utama matriks $\left(\mathbf{B}^T\mathbf{B}\right)^{-1}$. Tolak H_0 jika $|z| > z_{(\alpha/2)}$ atau $P - value < \alpha$ artinya bahwa semua fungsi basis yang terpilih dalam model *Multivariate Adaptive Generalized Poisson Regression Spline* (MAGPRS) memiliki pengaruh terhadap variabel respon.

2.9 Kematian Ibu

Kematian ibu adalah kematian yang terjadi saat kehamilan, atau selama 42 hari sejak terminasi kehamilan, tanpa memperhitungkan durasi dan tempat kehamilan, yang disebabkan atau diperparah oleh kehamilan atau pengelolaan kehamilan tersebut, tetapi bukan disebabkan oleh kecelakaan atau kebetulan (WHO, 2004). Penyebab kematian ibu antara lain komplikasi saat

kehamilan dan pasca kehamilan. Bentuk komplikasi yang menyebabkan kematian ibu antara lain pendarahan, infeksi, tekanan darah tinggi saat kehamilan, komplikasi persalinan, dan aborsi yang tidak aman. Indonesia mengukur kematian ibu dengan Angka Kematian Ibu (AKI). Menurut BPS, AKI didapat dari jumlah kematian ibu hamil atau melahir dibagi dengan jumlah kelahiran hidup.

Banyak faktor yang mempengaruhi kematian maternal. Banyak teori-teori tentang kematian ibu yang tercipta, tentunya oleh para ahli melalui proses penelitian. Menurut Dinas Kesehatan Provinsi Jawa Timur, indikator-indikator yang diduga mempengaruhi kematian ibu adalah ibu hamil yang melaksanakan program K1, ibu hamil yang melaksanakan program K4, pasangan yang melakukan program KB, komplikasi kebidanan yang ditolong oleh tenaga kesehatan, ibu hamil yang mendapatkan zat besi Fe3, ibu hamil yang mendapatkan imunisasi TT2+, banyak tenaga kesehatan, pelayanan kesehatan ibu nifas, ibu nifas yang mendapat vitamin A, dan rumah tangga berperilaku bersih dan sehat. Sedangkan menurut Mochtar (1998), faktor-faktor yang mempengaruhi kematian antara lain.

1. Faktor Umum : risiko kematian pada kelompok umur ibu hamil di bawah 20 tahun dan pada kelompok di atas 35 tahun adalah tiga kali lebih tinggi dari kelompok umur reproduksi sehat, yaitu 20-34 tahun.
2. Faktor Paritas : ibu dengan riwayat hamil dan bersalin lebih dari enam kali berisiko delapan kali lebih tinggi mengalami kematian.
3. Faktor Perawatan Antenatal : kesadaran ibu hamil untuk memeriksakan kandungannya masih rendah merupakan salah satu hal yang beresiko kematian ibu.
4. Faktor Penolong : sekitar 70-80% persalinan masih ditolong oleh dukun beranak, dan tidak mempertimbangkan fasilitas kebidanan yang memadai, beresiko terhadap kematian ibu.

5. Faktor Sarana dan Fasilitas : sarana dan fasilitas rumah sakit, penyediaan darah dan obat-obatan masih ada yang belum terjangkau oleh masyarakat.
6. Faktor Sistem Rujukan : agar pelayanan kebidanan mudah dicapai, pemerintah telah menetapkan seorang ahli kebidanan di setiap ibu kota/kabupaten, namun belum sempurna.
7. Faktor Lainnya : yaitu faktor sosial ekonomi, kepercayaan, budaya, pendidikan, ketidaktahuan dan sebagainya.

2.10 Kerangka Konsep Penelitian

Teori tentang faktor penyebab kematian ibu terbagi menjadi tiga, yaitu determinan dekat, determinan menengah, dan determinan jauh (McCarthy & Maine, 1992). Penjelasan mengenai factor penyebab kematian ibu adalah sebagai berikut.

1. Determinan dekat

Proses kejadian yang berpengaruh langsung terhadap kematian ibu, yaitu kehamilan itu sendiri dan komplikasi pada kehamilan, persalinan dan masa nifas. Contoh komplikasi pada kehamilan, perdarahan pervaginam (pada trisemester ketiga, persalinan, dan pasca persalinan), infeksi, keracunan kehamilan, dan lain-lain.

2. Determinan menengah

Proses kejadian yang mempengaruhi determinan dekat secara langsung. Proses kejadian yang tergolong dalam determinan ini adalah status kesehatan ibu (status gizi, status anemia, riwayat persalinan sebelumnya, dan lain-lain), status reproduksi (usia ibu, jumlah anak yang pernah dilahirkan, dan lain-lain), akses menuju pelayanan kesehatan (lokasi pelayanan kesehatan, kualitas perawatan), dan perilaku terhadap pelayanan kesehatan (penggunaan KB, pemeriksaan antenatal, penggunaan perawatan modern), dan lain-lain.

3. Determinan Jauh

Proses kejadian yang berpengaruh langsung terhadap determinan menengah. Determinan ini meliputi faktor sosio–kultural dan faktor ekonomi, seperti status wanita dalam keluarga

dan masyarakat, status keluarga dalam masyarakat, dan status masyarakat.

Dinas Kesehatan Provinsi Jawa Timur melakukan pendataan tentang kesehatan masyarakat Jawa Timur. Pendataan ini berguna untuk memberi informasi kepada masyarakat tentang status kesehatan masyarakat Jawa Timur. Beberapa variabel yang didata oleh Dinas Kesehatan Jawa Timur adalah kunjungan ibu hamil K1, kunjungan ibu hamil K4, ibu nifas mendapat vitamin A, persalinan ditolong tenaga kesehatan, tablet Fe3 pada ibu hamil, penanganan komplikasi kebidanan, rumah tangga ber-PHBS, dan peserta KB aktif, dan lain-lain. Peneliti menduga beberapa variabel yang telah disebutkan berpengaruh terhadap jumlah kematian ibu. Hal ini dikarenakan variabel-variabel tersebut sesuai dengan teori faktor penyebab kematian ibu yang dicetuskan oleh McCarthy & Maine (1992). Selain itu, Cahyani (2017) menggunakan beberapa variabel yang telah disebutkan sebagai penduga faktor-faktor yang mempengaruhi jumlah kematian ibu pada penelitiaannya yang berjudul Pemodelan Jumlah Kematian Ibu di Provinsi Jawa Timur Tahun 2015 dengan *Geographically Weighted Negative Binomial Regression.* Berdasarkan teori McCarthy & Maine (1992) dan penelitian terdahulu, kerangka konsep penelitian ini seperti pada Gambar 2.1. Penelitian ini tidak menggunakan variabel yang termasuk dalam determinan jauh.

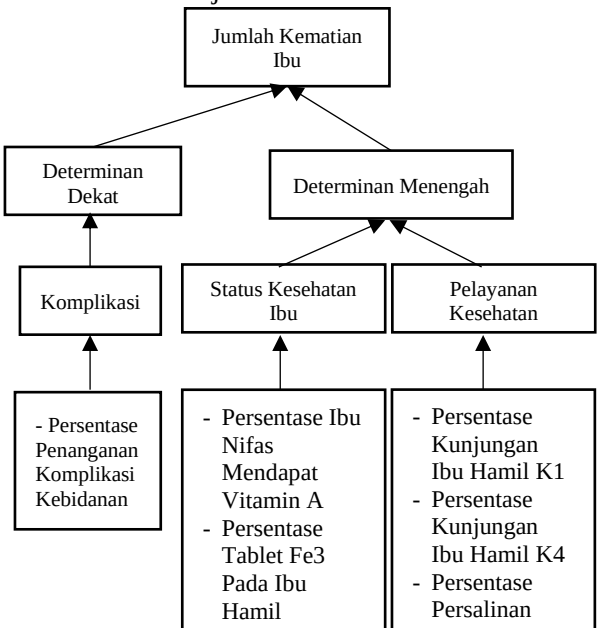

(*Halaman ini sengaja dikosongkan*)

BAB III

METODOLOGI PENELITIAN

3.1 Sumber Data

Data yang digunakan pada penelitian ini adalah data sekunder yang didapat dari publikasi Dinas Kesehatan Provinsi Jawa Timur, yaitu Profil Kesehatan Dinas Kesehatan Provinsi Jawa Timur Tahun 2018. Data yang dipakai adalah jumlah kematian ibu di Provinsi Jawa Timur Tahun 2018 beserta faktor-faktor yang diduga mempengaruhi.

3.2 Variabel Penelitian

Penelitian ini menggunakan dua variabel respon dan sepuluh variabel prediktor. Variabel-variabel tersebut seperti tertulis pada Tabel 3.1

Tabel 3.1 Data Penelitian

Variabel	Keterangan
Y_1	Jumlah Kematian Ibu
X_1	Persentase Kunjungan Ibu Hamil K1
X_2	Persentase Kunjungan Ibu Hamil K4
X_3	Persentase Ibu Nifas Mendapat Vitamin A
X_4	Persentase Persalinan Ditolong Tenaga Kesehatan
X_5	Persentase Ibu Hamil Mendapat Tablet Fe3
X_6	Persentase Penanganan Komplikasi Kebidanan
X_7	Presentase Peserta KB Aktif

Definisi operasional dari variabel-variabel penelitian menurut Dinas Kesehatan Provinsi Jawa Timur.

1. Jumlah kematian ibu adalah jumlah kematian ibu saat hamil, bersalin dan nifas.
2. Persentase kunjungan ibu hamil K1 adalah persentase banyak ibu hamil yang memperoleh pelayanan antenatal pertama kali dibandingkan jumlah sasaran ibu hamil di tiap kota atau kabupaten pada kurun waktu 1 tahun.

3. Persentase ibu hamil yang melaksanakan program K4 adalah persentase banyak ibu hamil yang memperoleh pelayanan antenatal sesuai dengan standar minimal 4 kali sesuai jadwal yang dianjurkan di tiap trimester dibandingkan jumlah sasaran ibu hamil di tiap kota atau kabupaten pada kurun waktu 1 tahun.
4. Persentase ibu nifas yang mendapat vitamin A adalah persentase jumlah ibu bersalin yang mendapat vitamin A dibandingkan total ibu nifas di tiap kota atau kabupaten pada kurun waktu 1 tahun.
5. Persentase persalinan ditolong tenaga kesehatan adalah persentase persalinan yang proses kelahirannya dibantu oleh tenaga kesehatan professional
6. Persentase ibu hamil mendapat tablet Fe3 adalah persentase ibu hamil yang mendapatkan tablet zat besi sebanyak 90 tablet sebagai upaya pencegahan anemia.
7. Persentase penanganan Ibu hamil mengalami komplikasi adalah persentase ibu hamil yang mempunyai kondisi berisiko/berbahaya pada waktu kehamilan maupun persalinan dan telah ditangani sesuai prosedur.
8. Persentase peserta KB aktif adalah persentase pasangan usia subur yang menggunakan KB baru dan aktif.

3.3 Struktur Data

Struktur data yang digunakan sesuai dengan jumlah variabel, yaitu satu variabel respon dan tujuh variabel prediktor, dan 38 kabupaten/kota sebagai unit penelitian. Struktur data tersebut seperti pada Tabel 3.2.

Tabel 3.2 Struktur Data Penelitian

Kabupaten / Kota	y_1	x_1	x_2	x_3	x_4	x_5	x_6	x_7
1	$y_{1,1}$	$y_{1,1}$	$y_{2,1}$	$y_{3,1}$	$y_{4,1}$	$y_{5,1}$	$y_{6,1}$	$y_{7,1}$
2	$y_{1,2}$	$y_{1,2}$	$y_{2,2}$	$y_{3,2}$	$y_{4,2}$	$y_{5,2}$	$y_{6,2}$	$y_{7,2}$
3	$y_{1,3}$	$y_{1,3}$	$y_{2,3}$	$y_{3,3}$	$y_{4,3}$	$y_{5,3}$	$y_{6,3}$	$y_{7,3}$
.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.

Tabel 3.2 Struktur Data Penelitian (Lanjutan)

Kabupaten / Kota	y_1	x_1	x_2	x_3	x_4	x_5	x_6	x_7
.	.	.	.	.	.	.	.	.
38	$y_{1,38}$	$x_{1,38}$	$x_{2,38}$	$x_{3,38}$	$x_{4,38}$	$x_{5,38}$	$x_{6,38}$	$x_{7,38}$

3.4 Langkah Penelitian

Langkah-langkah untuk menentukan faktor-faktor yang mempengaruhi jumlah kematian ibu di Jawa Timur dengan pendekatan MAGPRS adalah sebagai berikut.

1. Mendeskripsikan karakteristik jumlah kematian ibu di Provinsi Jawa Timur dan faktor-faktor yang diduga mempengaruhinya.
2. Melakukan pengujian *equidispersion*
3. Melakukan pemodelan MAGPRS dengan mengkombinasikan besarnya *Basis Function* (BF) yaitu 14, 21, dan 28, *Maximum Interaction* (MI) yaitu 1,2, dan 3, dan *Minimum Observation* (MO) yaitu 0,1,2, dan 3
4. Menentukan model terbaik dari MAGPRS berdasarkan nilai GCV terkecil
5. Melakukan pengujian simultan dan parsial model MAGPRS untuk mengetahui pengaruh variabel prediktor terhadap variabel respon.
6. Melakukan interpretasi model MAGPRS.
7. Melakukan analisis kepentingan variabel prediktor terhadap variabel respon dengan menggunakan GCV
8. Membuat kesimpulan dari hasil analisis

3.5 Diagram Alir

Berdasarkan langkah penelitian, diagram alir pada penelitian ini ditunjukkan pada Gambar 3.1.

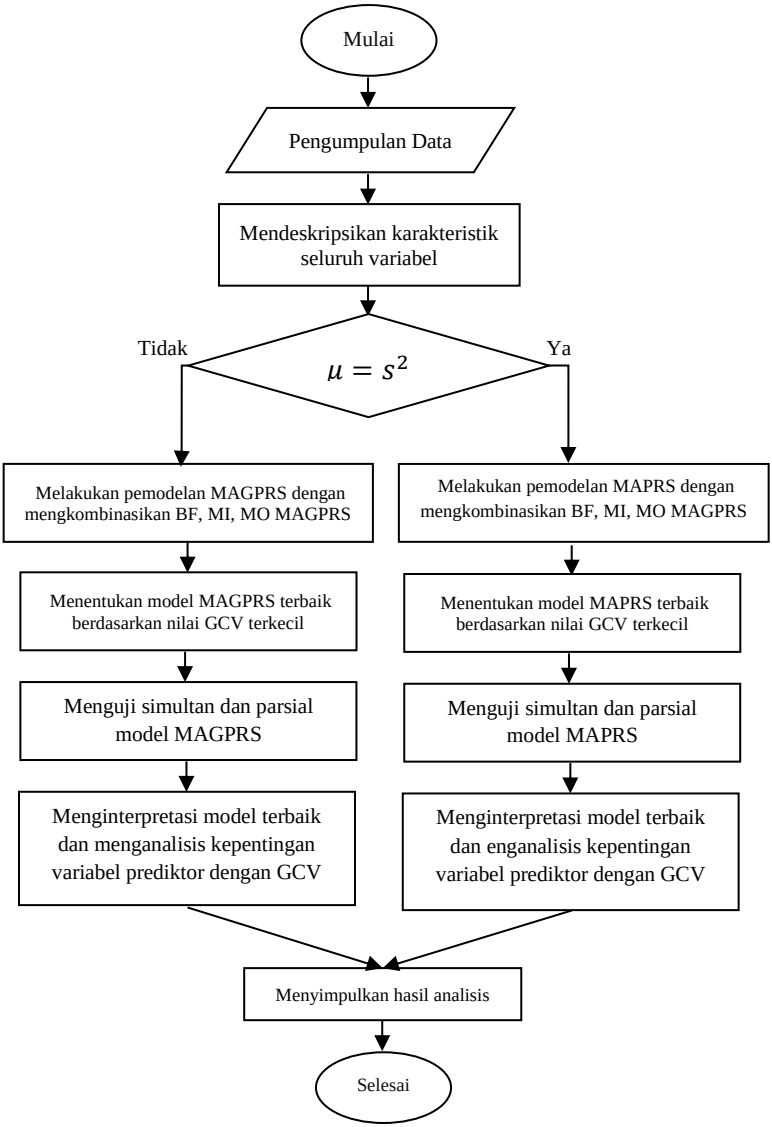

Gambar 3.1 Diagram Alir

BAB IV

ANALISIS DAN PEMBAHASAN

Bab ini membahas tentang jawaban dari rumusan masalah pada bab satu dalam bentuk analisis dan penjelasan. Hal-hal yang dibahas adalah karakteristik dari jumlah kematian ibu di Jawa Timur serta faktor-faktor yang diduga berpengaruh. Pemodelan *Multivariat Adaptive Generalized Poisson Regression Spline* pada jumlah kematian ibu di Jawa Timur juga dibahas untuk mengetahui pemodelan terbaik. Berikut merupakan analisis dan pembahasannya.

4.1 Karakteristik Jumlah Kematian Ibu di Jawa Timur Tahun 2018 dan Faktor-Faktor yang Diduga Berpengaruh

Subbab ini menjelaskan tentang karakteristik dari data yang digunakan dalam penelitian ini. Variabel respon pada penelitian ini yang adalah jumlah kematian ibu di Jawa Timur yang dijelaskan dalam bentuk diagram batang. Selain itu, menjelaskan tentang statistika deskriptif dari variabel respon dan variabel prediktor, serta pola hubungan antara variabel respon dan prediktor. Analisis karakteristis perlu dilakukan untuk mengetahui metode yang cocok digunakan untuk data pada penelitian ini.

Jawa Timur adalah salah satu provinsi yang memiliki jumlah kematian ibu yang tinggi. Jawa Timur menempati posisi ketiga provinsi yang memiliki angka kematian ibu terbesar di Indonesia pada tahun 2018. Angka kematian ibu di Jawa Timur pada tahun 2018 mencapai 91,45 per 100.000 kelahiran hidup, dimana angka tersebut mengalami penurunan dari tahun 2017 yang mencapai 91,92 per 100.000 kelahiran hidup. Walaupun sudah mengalami penurunan, namun angka tersebut masih besar. Angka kematian ibu yang besar disebabkan oleh jumlah kematian ibu yang tinggi. Tingginya jumlah kematian ibu di Jawa Timur dipengaruhi oleh jumlah kematian ibu di masing-masing kabupaten/kota. Gambar 4.1 menujukkan banyaknya jumlah kematian ibu pada setiap kabupaten/kota di Jawa Timur pada tahun 2018, yang mengacu pada Lampiran 1.

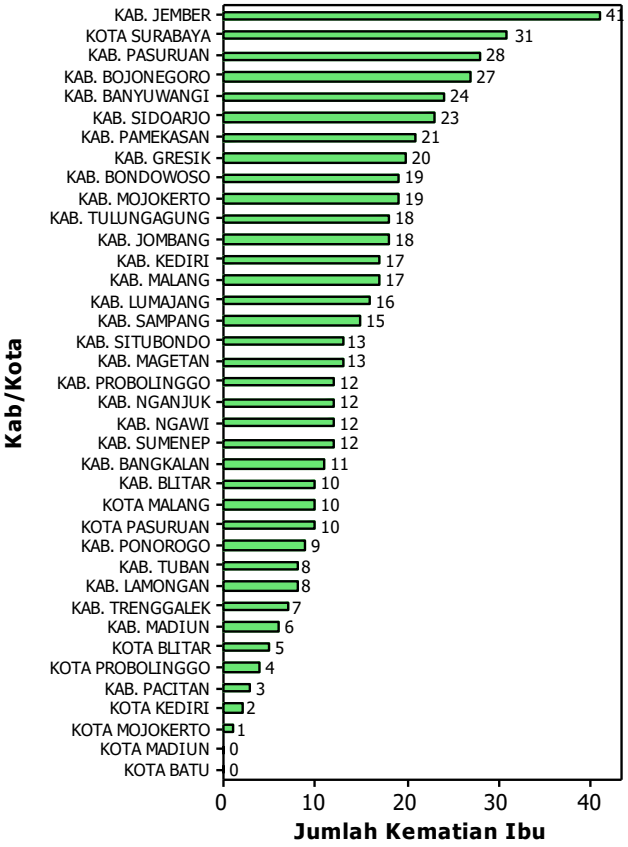

Gambar 4.1 Jumlah Kematian Ibu pada Setiap Kabupaten/Kota di Jawa Timur

Gambar 4.1 menunjukkan jumlah kematian ibu pada setiap kabupaten/kota di Jawa Timur tahun 2018, mulai dari yang terbesar hingga terkecil. Jumlah kematian ibu terbesar adalah Kabupaten Jember yaitu sebesar 41 kematian ibu, oleh karena itu Kabupaten Jember memberikan sumbangsih besar untuk AKI Jawa Timur yang tinggi pada tahun 2018. Posisi kedua terbesar

adalah Kota Surabaya dan Kabupaten Pasuruhan sebagai posisi ketiga jumlah kematian ibu terbesar di Jawa Timur. Jumlah kematian ibu Kota Surabaya dan Kabupaten Pasuruhan secara berurutan adalah 31 dan 28 kematian ibu. Jumlah kematian ibu yang paling kecil adalah Kota Madiun dan Kota Batu, yaitu tidak ada kematian ibu.

4.1.1 Statistika Deskriptif Jumlah Kematian Ibu di Jawa Timur Tahun 2018 dan Faktor-Faktor yang Diduga Berpengaruh

Analisis statistika deskriptif dilakukan untuk mengetahui karakteristik data seperti pada Lampiran 1 dalam hal *mean*, varians, nilai maksimal dan nilai minimal. Statistika deskriptif dari jumlah kematian ibu di Jawa Timur tahun 2018 beserta faktor-faktor yang diduga berpengaruh tercantum pada Tabel 4.1.

Tabel 4.1 Statistika Deskriptif Jumlah Kematian Ibu dan Faktor-Faktor yang Diduga Berpengaruh

Variabel	*Mean*	Varians	Min	Maks
Jumlah Kematian Ibu (y)	13,737	82,253	0	41
Persentase Kunjungan Ibu Hamil K1 (x_1)	99,120	17,013	88,947	107,444
Persentase Kunjungan Ibu Hamil K4 (x_2)	90,668	32,752	79,601	100,003
Persentase Ibu Nifas Mendapat Vitamin A (x_3)	90,674	55,782	68,306	100,000
Persentase Persalinan Ditolong Tenaga Kesehatan (x_4)	95,509	18,195	86,456	102,264
Persentase Ibu Hamil Mendapat Tablet Fe3 (x_5)	89,781	43,742	73,137	99,963
Persentase Penanganan Komplikasi Kebidanan (x_6)	98,718	323,146	51,460	147,894
Persentase Peserta KB Aktif (x_7)	75,815	28,201	67,696	88,849

Catatan : Data persentase lebih dari 100% karena data yang menjadi pembanding adalah data awal ibu hamil yang terdaftar pada perangkat kesehatan saja, sedangkan dipertengahan perjalanan pelayanan, terdapat penambahan ibu hamil yang menyebabkan jumlah pembanding lebih kecil.

Tabel 4.1 menginformasikan bahwa variabel respon (y) yaitu jumlah kematian ibu di Jawa Timur tahun 2018 memiliki nilai rata-rata sebesar 13,737. Nilai varians jumlah kematian ibu sebesar

82,253 yang artinya, data jumlah kematian ibu cukup beragam. Jumlah kematian ibu terendah adalah sebesar 0, yang artinya tidak ada kematian ibu terjadi di Kota Madiun dan Kota Batu, sedangkan jumlah kematian ibu tertinggi adalah sebesar 41 kematian ibu yang terjadi di Kabupaten Jember.

Rata-rata persentase kunjungan ibu hamil K1 (x_1) di Jawa Timur adalah 99,120%, artinya hampir semua ibu hamil di Jawa Timur sudah mendapatkan pelayanan atenatal pertama. Nilai variansnya sebesar 17,013, sehingga dapat dikatakan bahwa setiap kabupaten/kota di Jawa Timur memiliki sedikit perbedaan dalam pelayanan atenatal pertama. Persentase kunjungan ibu hamil K1 paling kecil terjadi di Kabupaten Nganjuk, yaitu sebesar 88,947%, sedangkan paling besar terjadi di Kabupaten Lumajang, yaitu sebesar 107,44%, maka dapat dikatakan bahwa jumlah ibu hamil yang melakukan kunjungan K1 di Kabupaten Lumajang lebih banyak dibanding jumlah ibu hamil yang terdata di Kabupaten Lumajang, sehingga persentase lebih dari 100%..

Persentase kunjungan ibu hamil K4 (x_2) di Jawa Timur memiliki rata-rata sebesar 90,668%, artinya hampir semua ibu hamil di Jawa Timur sudah mendapatkan pelayanan atenatal minimal 4 kali dalam setahun. Nilai variansnya sebesar 32.752, sehingga dapat dikatakan bahwa setiap kabupaten/kota di Jawa Timur memiliki sedikit perbedaan dalam pelayanan atenatal minimal 4 tahun dalam setahun. Persentase kunjungan ibu hamil K4 paling kecil yaitu 79,601% terjadi di Kabupaten Nganjuk, sedangkan paling besar terjadi di Kabupaten Sidoarjo, yaitu sebesar 100,003%, maka dapat dikatakan bahwa jumlah ibu hamil yang melakukan kunjungan K4 di Kabupaten Sidoarjo lebih banyak dibanding jumlah ibu hamil yang terdata di Kabupaten Sidoarjo, sehingga persentase lebih dari 100%..

Rata-rata persentase ibu nifas mendapat vitamin A (x_3) di Jawa Timur adalah 90,674%, artinya hampir semua ibu bersalin di Jawa Timur mendapat vitamin A. Nilai variansnya sebesar 55,782, sehingga dapat dikatakan bahwa setiap kabupaten/kota di Jawa Timur cukup berbeda dalam hal pemberian vitamin A pada ibu

bersalin. Persentase ibu nifas mendapat vitamin A paling kecil terjadi di Kabupaten Ponorogo, yaitu sebesar 68,306%, sedangkan paling besar terjadi di Kabupaten Lamongan, yaitu sebesar 100,000%.

Persentase persalinan ditolong tenaga kesehatan (x_4) di Jawa Timur memiliki rata-rata sebesar 95,509%, artinya hampir semua persalinan di Jawa Timur dibantu tenaga kesehatan. Nilai variansnya adalah sebesar 18,195, sehingga dapat dikatakan bahwa setiap kabupaten/kota di Jawa Timur memiliki sedikit perbedaan dalam hal persalinan yang ditolong tenaga kesehatan. Persentase persalinan ditolong tenaga kesehatan paling kecil yaitu sebesar 86,456% terjadi di Kabupaten Pacitan, sedangkan paling besar terjadi di Kabupaten Lumajang, yaitu sebesar 102,264%, maka dapat dikatakan bahwa jumlah ibu hamil yang persalinannya dibantu tenaga kesehatan di Kabupaten Lumajang lebih banyak dibanding jumlah ibu hamil yang terdata di Kabupaten Lumajang, sehingga persentase lebih dari 100%.

Rata-rata persentase ibu hamil mendapat tablet Fe3 (x_5) di Jawa Timur adalah 89,781%, artinya hampir semua ibu hamil di Jawa Timur mendapatkan tablet Fe3. Nilai variansnya adalah sebesar 43,742, sehingga dapat dikatakan bahwa setiap kabupaten/kota di Jawa Timur cukup perbedaan dalam pemberian tablet Fe3. Persentase ibu hamil mendapat tablet Fe3 paling kecil terjadi di Kabupaten Ngawi, yaitu sebesar 73,137%, sedangkan paling besar yaitu 99,963% terjadi di Kota Madiun.

Persentase penanganan komplikasi kebidanan (x_6) di Jawa Timur memiliki rata-rata sebesar 98,718%, artinya hampir semua ibu hamil yang mengalami komplikasi di Jawa Timur sudah sudah ditangani. Nilai variansnya adalah sebesar 323,146, sehingga dapat dikatakan bahwa setiap kabupaten/kota di Jawa Timur sangat berbeda dalam penanganan komplikasi kebidanan. Persentase penanganan komplikasi kebidanan paling kecil yaitu sebesar 51,469% terjadi di Kota Kediri, sedangkan paling besar terjadi di Kabupaten Bondowoso, yaitu sebesar 147,894%, maka dapat dikatakan bahwa di Kabupaten Bondowoso memiliki jumlah ibu

hamil yang ditangani oleh kebidanan lebih banyak dibanding jumlah ibu hamil yang terdata di Kabupaten Bondowoso, sehingga persentase lebih dari 100%.

Rata-rata persentase peserta KB aktif (x_7) di Jawa Timur adalah 75,815%, artinya lebih dari setengah keluarga di Jawa Timur mengikuti KB aktif. Nilai variansnya adalah sebesar 28,201, sehingga dapat dikatakan bahwa setiap kabupaten/kota di Jawa Timur memiliki sedikit perbedaan dalam keikutsertaan KB aktif. Persentase peserta KB aktif paling kecil terjadi di Kota Madiun, yaitu sebesar 67,696%, sedangkan paling besar terjadi di Kabupaten Jember, yaitu sebesar 88,849%.

4.1.2 Pola Hubungan Jumlah Kematian Ibu di Jawa Timur Tahun 2018 dan Faktor-Faktor yang Diduga Berpengaruh

Mengetahui pola hubungan antara variabel respon dan prediktor diperlukan untuk mendeteksi metode yang cocok untuk data tersebut. *Scatterplot* adalah salah satu cara untuk mengetahui pola hubungan antara jumlah kematian ibu sebagai respon dengan masing variabel prediktor yang diduga. Gambar 4.2 merupakan *scatterplot* antara jumlah kematian ibu dengan variabel predictor yang diduga berpengaruh.

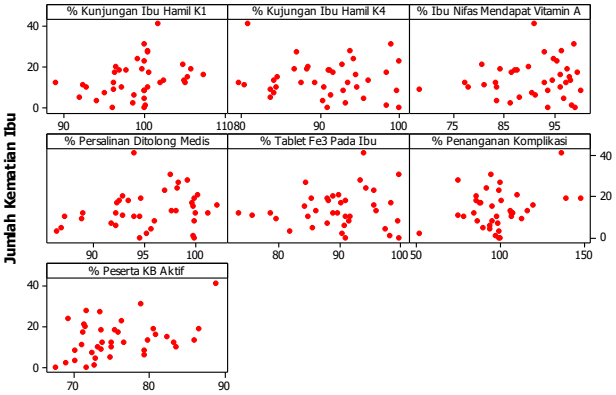

Gambar 4.2 *Scatterplot* Jumlah Kematian Ibu dan Faktor-Faktor yang Diduga Berpengaruh

Berdasarkan Gambar 4.2 diperoleh informasi bahwa pola hubungan antara jumlah kematian ibu di Jawa Timur dengan variabel-variabel yang diduga berpengaruh tidak membentuk pola tertentu. Hal tersebut berarti apabila jumlah kematian ibu di Jawa Timur tinggi maka ketujuh variabel terduga tersebut belum tentu tinggi atau rendah, dan sebaliknya apabila jumlah kematian ibu rendah maka ketujuh variabel terduga belum tentu rendah atau tinggi, sehingga seluruh variabel yang diduga berpengaruh terhadap jumlah kematian ibu merupakan komponen nonparametrik. Oleh karena itu dalam pemodelan yang digunakan adalah pemodelan nonparametrik *spline*. Hubungan antara variabel respon dan prediktor juga dapat diketahui dengan melihat nilai korelasi dimana menggunakan rumus pada persamaan (2.33). Pada penelitian ini transformasi menggunakan invers dari data. Nilai korelasi antara jumlah kematian ibu dengan variabel-variabel yang diduga berpengaruh ditampilkan pada Tabel 4.2.

Tabel 4.2 Nilai Korelasi dan P-*value* Variabel Prediktor terhadap Variabel Respon

Variabel	Nilai Korelasi	P-*Value*
x_1	0,296	0,071
x_2	-0,095	0,570
x_3	0,094	0,573
x_4	0,233	0,159
x_5	0,104	0,536
x_6	0,294	0,074
x_7	0,368	0,023

Berdasarkan Tabel 4.2 diketahui bahwa variabel persentase kunjungan ibu hamil K4 (x_2) memiliki korelasi yang negatif terhadap jumlah kematian ibu di Jawa Timur, artinya apabila persentase variabel x_2, meningkat maka jumlah kematian ibu di Jawa Timur akan menurun. Persentase kunjungan ibu hamil K1 (x_1), persentase ibu nifas mendapat vitamin A (x_3), persentase persalinan ditolong tenaga kesehatan (x_4), persentase ibu hamil mendapat tablet Fe3 (x_5), persentase penanganan komplikasi kebidanan (x_6), dan persentase peserta KB aktif (x_7) memiliki

korelasi yang positif terhadap jumlah kematian ibu di Jawa Timur, artinya apabila persentase variabel x_1, x_3, x_4, x_5, x_6, dan x_7 meningkat maka jumlah kematian ibu di Jawa Timur akan meningkat pula.

Jika dilihat nilai P-*value*nya variabel x_1, x_2, x_3, x_4, x_5, dan x_6 memiliki nilai P-*value* yang lebih besar dari $\alpha(0{,}05)$ sehingga dapat dikatakan variabel-varibel tersebut tidak memiliki korelasi/hubungan linier dengan variabel respon. Variabel x_7 memiliki P-*value* kurang dari $\alpha(0{,}05)$, sehingga dapat dikatakan variabel ini memiliki hubungan linier dengan variabel respon. Sebagian besar variabel prediktor tidak memiliki hubungan yang linier terhadap variabel respon, sehingga dapat dilakukan analisis dengan pendekatan nonparametrik.

4.2 Pemodelan Jumlah Kematian Ibu di Jawa Timur Tahun 2018 dengan *Multivariate Adaptive Generalized Poisson Regression Spline* (MAGPRS)

Pemodelan jumlah kematian ibu di Jawa Timur pada penelitian ini menggunakan MAGPRS. Sebelum menginterpretasi model terbaik, langkah-langkah yang harus dilakukan adalah melakukan uji equidispersi, kemudian mendapatkan model terbaik dengan nilai GCV terkecil. Langkah selanjutnya adalah melakukan uji simultan dan parsial untuk menguji pengaruh variabel terhadap model. Langkah terakhir adalah melakukan interpretasi model terbaik, untuk mendapatkan informasi yang bermanfaat. Seluruh Langkah yang dilakukan sesuai langkah penelitian pada Bab 3.

4.2.1 Pendeteksi Equidispersi

Penelitian ini menggunakan uji Khi Kuadrat Pearson dan *software* R untuk menguji equidispersi sesuai dengan persamaan (2.23). *Output* uji equidispersi pada penelitian ini sesuai dengan Lampiran 2. Dilakukan uji Khi Kuadrat Pearson pada variabel respon seperti pada Tabel 4.3.

Tabel 4.3 Pengujian Equidispersi dengan Uji Khi Kuadrat Pearson

$\bar{y}$	s^2	VT
13,736	82,253	221,561

Berdasarkan Tabel 4.3, nilai VT dengan perhitungan manual sesuai rumus (2.23) sebesar 221,561. Nilai VT tersebut lebih dari 1 sehingga tidak terjadi equidispersi, namun data mengalami overdispersi.

Pengujian ekuidispersi dengan *software* R didapatkan *output* nilai dispersi sebesar 4.242 dan *p-value* sebesar 0,007. *P-value* kurang dari α (0,05), sehingga menghasilkan keputusan tolak H_0 yang berarti varians tidak sama dengan rata-rata atau data tersebut mengalami overdispersi. Pengujian equidispersi dengan uji Khi Kuadrat Pearson dan *software* R menghasilkan kesimpulan yang sama, yaitu terjadi overdispersi pada data, sehingga metode *generalized poisson* cocok diterapkan. Pola data penelitian ini tidak tertentu, data overdispersi, dan data memiliki variabel prediktor lebih dari 3, maka dari itu metode *Multivariate Adaptive Generalized Poisson Regression Spline* (MAGPRS) cocok di terapkan.

4.2.2 Model MAGPRS Terbaik pada Jumlah Kematian Ibu

Pembentukan model MAGPRS memperhatikan tiga komponen, yaitu basis fungsi (BF), maksimum interaksi (MI), dan minimum observasi (MO). Variabel prediktor yang diduga berpengaruh berjumlah 7 variabel sehingga kombinasi BF adalah 14, 21, dan 28. MI yang digunakan pada penelitian ini adalah 1, 2, dan 3. MO yang digunakan dalam penelitian ini adalah 0, 1, 2, dan 3. GCV dan R^2 dari kombinasi BF, MI, MO seusia dengan rumus pada persamaan (2.31) dan (2.32). *Output software* R unutk pemodelan MAGPRS terlampir pada Lampiran 3 serta tercantum pada Tabel 4.4.

Tabel 4.4 Hasil Percobaan Pembentukan Model MAGPRS antara Jumlah Kematian Ibu dengan Faktor-Faktor yang Diduga Berpengaruh

Nomer Model	Kombinasi			GCV	R^2
	BF	MI	MO		
1	14	1	0	0,0008815	0,8278344
2	14	1	1	0,0004777	0,9066987
3	14	1	2	0,0005037	0,9016153
4	14	1	3	0,0004956	0,9031969
5	14	2	0	0,0007525	0,8530196
6	14	2	1	0,0005329	0,8959253
7	14	2	2	0,0004221	0,9175526
8	14	2	3	0,0004934	0,9036391
9	14	3	0	0,0007525	0,8530196
10	14	3	1	0,0005388	0,8947716
11	14	3	2	0,0004221	0,9175526
12	14	3	3	0,0004934	0,9036391
13	21	1	0	0,0007931	0,8450992
14	21	1	1	0,000281	0,9451184
15	21	1	2	0,0002484	0,9514781
16	21	1	3	0,0003525	0,9311494
17	21	2	0	0,0006304	0,8768721
18	21	2	1	0,0003842	0,9249683
19	21	2	2	0,0002063	0,9597152
20	21	2	3	0,0003653	0,9286499
21	21	3	0	0,0006304	0,8768721
22	21	3	1	0,0002962	0,9421393
23	21	3	2	0,0002063	0,9597152
24	21	3	3	0,0003653	0,9286499
25	28	1	0	0,0006211	0,878686
26	28	1	1	0,0002091	0,9591564

Tabel 4.4 (Lanjutan) Hasil Percobaan Pembentukan Model MAGPRS antara Jumlah Kematian Ibu dengan Faktor-Faktor yang Diduga Berpengaruh

Nomer Model	Kombinasi			GCV	R^2
	BF	MI	MO		
27	28	1	2	0,0001343	0,9737682
28	28	1	3	0,0003334	0,9348749
29	28	2	0	0,0002531	0,950571
30	28	2	1	0,0002424	0,9526618
31	**28**	**2**	**2**	**0,0001198**	**0,9766097**
32	28	2	3	0,0002451	0,9521313
33	28	3	0	0,0002531	0,950571
34	28	3	1	0,0002737	0,946538
35	28	3	2	0,0001206	0,9764509
36	28	3	3	0,0002451	0,9521313

Berdasarkan Tabel 4.4, kombinasi BF, MI, dan MO terbaik adalah kombinasi nomer 31, karena memiliki nilai GCV paling kecil, yaitu 0.0001198 dan nilai R^2 sebesar 0,9766097. Model terbaik tersebut pada BF=28, MI=2, dan MO=2. Kemudian dilakukan *backward stepwise* pada basis fungsi, maka menjadi 24 basis fungsi.

4.2.3 Pengujian Simultan Model MAGPRS Terbaik

Pengujian simultan bertujuan untuk mengetahui pengaruh variabel prediktor secara serentak terhadap variabel respon. Hasil uji simultan dengan bantuan *software* R yang sesuai dengan persamaan (2.63) tercantum pada Tabel 4.5.

Tabel 4.5 Hasil Pengujian Simultan Model MAGPRS Terbaik

G^2	$\chi^2_{(0,05;23)}$	Keputusan
1793.918	35.172	Tolak H_0

Tabel 4.5 memberi informasi bahwa didapatkan G^2 sebesar 179,918 yang lebih besar dari $\chi^2_{(0,05;23)}$, sehingga menghasilkan keputusan tolak H_0. Kesimpulan dari pengujian simultan adalah paling sedikit ada satu fungsi basis yang memuat variabel prediktor

yang berpengaruh terhadap variabel respon. Selanjutnya akan dilakukan uji parsial.

4.2.4 Pengujian Parsial Parameter Model MAGPRS Terbaik

Uji parsial dilakukan untuk mengetahui basis fungsi yang berpengaruh signifikan terhadap model. Tabel 4.6 merupakan *output* dari pengujian parsial pada penelitian ini sesuai dengan Lampiran 7.

Tabel 4.6 Hasil Pengujian Parsial Parameter Model MAGPRS Terbaik

Parameter	Nilai Taksiran	SE	z	P-*value*
(Intercept)	21,1	0,000	$2{,}65.10^{15}$	0,000
$h(X_7\text{-}72.8313)$	-254	0,000	$-4{,}34.10^{17}$	0,000
$h(72.8313\text{-}X_7)$	95,1	0,000	$5{,}06.10^{16}$	0,000
$h(X_3\text{-}98.778)$	115000	0,000	$1{,}75.10^{17}$	0,000
$h(98.778\text{-}X_3)$	191	0,000	$3{,}53.10^{17}$	0,000
$h(X_1\text{-}98.6576)$	148	0,000	$1{,}78.10^{17}$	0,000
$h(98.6576\text{-}X_1)$	-385	0,000	$-2{,}94.10^{17}$	0,000
$h(X_2\text{-}98.3972)$	-1680	0,000	$-4{,}55.10^{17}$	0,000
$h(98.3972\text{-}X_2)$	246	0,000	$5{,}49.10^{17}$	0,000
$h(98.6576\text{-}X_1)*h(X_3\text{-}83.5462)$	-64	0,000	$-3{,}84.10^{17}$	0,000
$h(98.6576\text{-}X_1)*h(83.5462\text{-}X_3)$	-211	0,000	$-6{,}25.10^{17}$	0,000
$h(X_6\text{-}89.6465)*h(72.8313\text{-}X_7)$	-159	0,000	$-7{,}08.10^{17}$	0,000
$h(89.6465\text{-}X_6)*h(72.8313\text{-}X_7)$	-55.1	0,000	$-4{,}93.10^{17}$	0,000
$h(X_1\text{-}97.2565)*h(98.778\text{-}X_3)$	-38.7	0,000	$-1{,}64.10^{17}$	0,000
$h(X_6\text{-}97.9622)$	14.8	0,000	$1{,}31.10^{17}$	0,000
$h(97.9622\text{-}X_6)$	105	0,000	$3{,}21.10^{17}$	0,000
$h(X_3\text{-}98.778)*X_7$	-1560	0,000	$-1{,}68.10^{17}$	0,000
$h(X_5\text{-}91.5021)*h(X_7\text{-}72.8313)$	85,7	0,000	$6{,}11.10^{17}$	0,000
$h(91.5021\text{-}X_5)*h(X_7\text{-}72.8313)$	6,02	0,000	$9{,}58.10^{16}$	0,000
$h(X_4\text{-}95.3338)*h(97.9622\text{-}X_6)$	0,43	0,000	$5{,}38.10^{15}$	0,000

Tabel 4.6 (Lanjutan) Hasil Pengujian Parsial Parameter Model MAGPRS Terbaik

Parameter	Nilai Taksiran	SE	z	P-*value*
h(95.3338-X_4)*h(97.9622-X_6)	-16,9	0,000	-1,57.10^{17}	0,000
h(X_5-90.946)	-57,8	0,000	-6,12.10^{16}	0,000
h(98.778-X_3)*h(X_4-92.3872)	14,6	0,000	7,74.10^{16}	0,000
h(98.778-X_3)*h(92.3872-X_4)	17,7	0,000	3,18.10^{17}	0,000
θ	-0,367	0,027	-13,518	0,000

Pengujian parsial dilakukan dengan membandingkan |nilai z| pada masing-masing basis fungsi dengan z_{tabel}. z_{tabel} pada penelitian ini adalah $z_{0,025}$ = 1,96. Berdasarkan Tabel 4.6 diketahui bahwa |nilai *z*| seluruh fungsi basis memiliki nilai yang lebih besar dari $z_{0,025}$, sehingga menghasilkan kesimpulan tolak H_0. Kesimpulan dari pengujian parsial adalah semua fungsi basis yang terpilih dalam model MAGPRS berpengaruh signifikan terhadap variabel respon, yang adalah jumlah kematian ibu di Jawa Timur.

4.2.5 Interpretasi Model MAGPRS Terbaik

Pemodelan pada penelitian ini adalah sesuai model umum MAGPRS pada persamaan (2.49). Persamaan model MAGPRS jumlah kematian ibu di Jawa Timur yang dipengaruhi oleh variabel- variabel prediktor adalah sebagai berikut.

$$\hat{\mu} = \exp\left[\begin{array}{l} 0{,}02105783-0{,}3849239*h(98{,}6576-X_1)+0{,}1482016*h(X_1-98{,}6576) \\ +0{,}2464435*h(98{,}3972-X_2)-1{,}6793*h(X_2-98{,}3972) \\ +0{,}190538*h(98{,}778-X_3)+114{,}746*h(X_3-98{,}778) \\ -0{,}05784128*h(X_5-90{,}946)+0{,}104468*h(97{,}9622-X_6) \\ +0{,}0148089*h(X_6-97{,}9622)+0{,}09511318*h(72{,}8313-X_7) \\ -0{,}254227*h(X_7-72{,}8313)-1{,}562888*h(X_3-98{,}778)*X_7 \\ -0{,}03869788*h(X_1-97{,}2565)*h(98{,}778-X_3) \\ -0{,}0640392*h(98{,}6576-X_1)*h(X_3-83{,}5462) \\ -0{,}2104967*h(98{,}6576-X_1)*h(83{,}5462-X_3) \\ +0{,}01461118*h(98{,}778-X_3)*h(X_4-92{,}3872) \\ +0{,}01772304*h(98{,}778-X_3)*h(92{,}3872-X_4) \\ -0{,}01690982*h(95{,}3338-X_4)*h(97{,}9622-X_6) \\ +0{,}000430426*h(X_4-95{,}3338)*h(97{,}9622-X_6) \\ +0{,}006016684*h(91{,}5021-X_5)*h(X_7-72{,}8313) \\ +0{,}08568682*h(X_5-91{,}5021)*h(X_7-72{,}8313) \\ -0{,}05511934*h(89{,}6465-X_6)*h(72{,}8313-X_7) \\ -0{,}1585744*h(X_6-89{,}6465)*h(72{,}8313-X_7) \end{array}\right]$$

dimana fungsi basisnya adalah sebagai berikut.

BF1	=	$h(98.6576-X_1)$	BF12	=	$X_7h(X_1-97.2565)$
BF2	=	$h(X_1-98.6576)$	BF13	=	$h(X_3-83.5462)$
BF3	=	$h(98.3972-X_2)$	BF14	=	$h(83.5462-X_3)$
BF4	=	$h(X_2-98.3972)$	BF15	=	$h(X_4-92.3872)$
BF5	=	$h(98.778-X_3)$	BF16	=	$h(92.3872-X_4)$
BF6	=	$h(X_3-98.778)$	BF17	=	$h(95.3338-X_4)$
BF7	=	$h(X_5-90.946)$	BF18	=	$h(X_4-95.3338)$
BF8	=	$h(97.9622-X_6)$	BF19	=	$h(91.5021-X_5)$
BF9	=	$h(X_6-97.9622)$	BF20	=	$h(X_5-91.5021)$
BF10	=	$h(72.8313-X_7)$	BF21	=	$h(89.6465-X_6)$
BF11	=	$h(X_7-72.8313)$	BF22	=	$h(X_6-89.6465)$

Persamaan MAGPRS akan dijabarkan untuk memudahkan interpretasi sebagai berikut.

1)	+	0,02105783		
2)	-	0,3849239	*	BF1 =
	-	0,3849239	*	$h(98{,}6576 - X_1)$
3)	+	0,1482016	*	BF2 =
	+	0,1482016	*	$h(X_1 - 98{,}6576)$
4)	+	0,2464435	*	BF3 =
	+	0,2464435	*	$h(98{,}3972 - X_2)$
5)	-	1,6793	*	BF4 =
	-	1,6793	*	$h(X_2 - 98{,}3972)$
6)	+	0,190538	*	BF5 =
	+	0,190538	*	$h(98{,}778 - X_3)$
7)	+	114,7456	*	BF6 =
	+	114,7456	*	$h(X_3 - 98{,}778)$
8)	-	0,05784128	*	BF7 =
	-	0,05784128	*	$h(X_5 - 90{,}946)$
9)	+	0,104468	*	BF8 =
	+	0,104468	*	$h(97{,}9622 - X_6)$
10)	+	0,0148089	*	BF9 =
	+	0,0148089	*	$h(X_6 - 97{,}9622)$
11)	+	0,09511318	*	BF10 =
	+	0,09511318	*	$h(72{,}8313 - X_7)$
12)	-	0,254227	*	BF11 =
	-	0,254227	*	$h(X_7 - 72{,}8313)$
13)	-	1,562888	*	BF6 * X_7 =
	-	1,562888	*	$h(X_3 - 98{,}778) * X_7$
14)	-	0,03869788	*	$h(X_1 - 97{,}2565)$ * BF5 =
	-	0,03869788	*	$h(X_1 - 97{,}2565) * h(98{,}778 - X_3)$
15)	-	0,0640392	*	BF1 * BF13 =
	-	0,0640392	*	$h(98{,}6576 - X_1) * h(X_3 - 83{,}5462)$
16)	-	0,2104967	*	BF1 * BF14 =
	-	0,2104967	*	$h(98{,}6576 - X_1) * h(83{,}5462 - X_3)$
17)	+	0,01461118	*	BF5 * BF15 =
	+	0,01461118	*	$h(98{,}778 - X_3) * h(X_4 - 92{,}3872)$
18)	+	0,01772304	*	BF5 * BF16 =
	+	0,01772304	*	$h(98{,}778 - X_3) * h(92{,}3872 - X_4)$
19)	-	0,01690982	*	BF17 * BF8 =

	-	0,01690982	*	$h(95{,}3338 - X_4) * h(97{,}9622 - X_6)$
20)	+	0,00043042	*	BF18 * BF8 =
	+	0,00043042	*	$h(X_4 - 95{,}3338) * h(97{,}9622 - X_6)$
21)	+	0,00601668	*	BF19 * BF11 =
	+	0,00601668	*	$h(91{,}5021 - X_5) * h(X_7 - 72{,}8313)$
22)	+	0,08568682	*	BF20 * BF11 =
	+	0,08568682	*	$h(X_5 - 91{,}5021) * h(X_7 - 72{,}8313)$
23)	-	0,05511934	*	BF21 * BF10 =
	-	0,05511934	*	$h(89{,}6465 - X_6) * h(72{,}8313 - X_7)$
24)	-	0,1585744	*	BF22 * BF10 =
	-	0,1585744	*	$h(X_6 - 89{,}6465) * h(72{,}8313 - X_7)$

Interpretasi masing-masing model adalah sebagai berikut.

2) $-0{,}3849239 * BF1 = -0{,}3849239 * h(98{,}6576 - X_1)$

$$-0{,}3849239 * h(98{,}6576 - X_1) = \begin{cases} (98{,}6576 - X_1); X_1 < 98{,}6576 \\ 0; X_1 \geq 98{,}6576 \end{cases}$$

Artinya, untuk kabupaten/kota yang memiliki persentase kunjungan ibu hamil K1 kurang dari 98,6576%, apabila kunjungan ibu hamil K1 bertambah 1% maka jumlah kematian ibu akan menurun sebesar *exp*(0,3849239), jika basis fungsi yang lain konstan.

3) $+0{,}1482016 * BF2 = +0{,}1482016 * h(X_1 - 98{,}6576)$

$$+0{,}1482016 * h(X_1 - 98{,}6576) = \begin{cases} (X_1 - 98{,}6576); X_1 > 98{,}6576 \\ 0; X_1 \leq 98{,}6576 \end{cases}$$

Artinya, untuk kabupaten/kota yang memiliki persentase kunjungan ibu hamil K1 lebih dari 98,6576%, apabila kunjungan ibu hamil K1 bertambah 1% maka jumlah kematian ibu akan meningkat sebesar *exp*(0,1482016), jika basis fungsi yang lain konstan.

4) $+0{,}2464435 * BF3 = +0{,}2464435 * h(98{,}3972 - X_2)$

$$+0,2464435 * h(98,3972 - X_2) = \begin{cases} (98,3972 - X_2); X_2 < 98,3972 \\ 0; X_2 \geq 98,3972 \end{cases}$$

Artinya, untuk kabupaten/kota yang memiliki persentase kunjungan ibu hamil K4 kurang dari 98,3972%, apabila kunjungan ibu hamil K4 bertambah 1% maka jumlah kematian ibu akan meningkat sebesar *exp*(0,2464435), jika basis fungsi yang lain konstan.

5) $-1,6793 * BF4 = -1,6793 * h(X_2 - 98,3972)$

$$-1,6793 * h(X_2 - 98,3972) = \begin{cases} (X_2 - 98,3972); X_2 > 98,3972 \\ 0; X_2 \leq 98,3972 \end{cases}$$

Artinya, untuk kabupaten/kota yang memiliki persentase kunjungan ibu hamil K4 lebih dari 98,3972%, apabila kunjungan ibu hamil K4 bertambah 1% maka jumlah kematian ibu akan menurun sebesar *exp*(1,6793), jika basis fungsi yang lain konstan.

6) $+0,190538 * BF5 = +0,190538 * h(98,778 - X_3)$

$$+0,190538 * h(98,778 - X_3) = \begin{cases} (98,778 - X_3); X_3 < 98,778 \\ 0; X_3 \geq 98,778 \end{cases}$$

Artinya, untuk kabupaten/kota yang memiliki persentase pemberian vitamin A pada ibu nifas kurang dari 98,778%, apabila pemberian vitamin A pada ibu nifas bertambah 1% maka jumlah kematian ibu akan meningkat sebesar *exp*(0,190538), jika basis fungsi yang lain konstan.

7) $+114,7456 * BF6 = +114,7456 * h(X_3 - 98,778)$

$$+114,7456 * h(X_3 - 98,778) = \begin{cases} (X_3 - 98,778); X_3 > 98,778 \\ 0; X_3 \leq 98,778 \end{cases}$$

Artinya, untuk kabupaten/kota yang memiliki persentase pemberian vitamin A pada ibu nifas lebih dari 98,778%, apabila pemberian vitamin A pada ibu nifas bertambah 1% maka

jumlah kematian ibu akan meningkat sebesar *exp*(114,7456), jika basis fungsi yang lain konstan.

8) $-0,05784128 * BF7 = -0,05784128 * h(X_5 - 90,946)$

$$-0,05784128 * h(X_5 - 90,946) = \begin{cases} (X_5 - 90,946); X_5 > 90,946 \\ 0; X_5 \le 90,946 \end{cases}$$

Artinya, untuk kabupaten/kota yang memiliki persentase pemberian Fe3 pada ibu hamil lebih dari 90,946%, apabila pemberian Fe3 pada ibu hamil bertambah 1% maka jumlah kematian ibu akan menurun sebesar *exp*(0,05784128), jika basis fungsi yang lain konstan.

9) $+0,104468 * BF8 = +0,104468 * h(97,9622 - X_6)$

$$+0,104468 * h(97,9622 - X_6) = \begin{cases} (97,9622 - X_6); X_6 < 97,9622 \\ 0; X_6 \ge 97,9622 \end{cases}$$

Artinya, untuk kabupaten/kota yang memiliki persentase penanganan komplikasi kebidanan kurang dari 97,9622%, apabila penanganan komplikasi kebidanan bertambah 1% maka jumlah kematian ibu akan meningkat sebesar *exp*(0,104468), jika basis fungsi yang lain konstan.

10) $+0,0148089 * BF9 = +0,0148089 * h(X_6 - 97,9622)$

$$+0,0148089 * h(X_6 - 97,9622) = \begin{cases} (X_6 - 97,9622); X_6 > 97,9622 \\ 0; X_6 \le 97,9622 \end{cases}$$

Artinya, untuk kabupaten/kota yang memiliki persentase penanganan komplikasi kebidanan lebih dari 97,9622%, apabila penanganan komplikasi kebidanan bertambah 1% maka jumlah kematian ibu akan meningkat sebesar *exp*(0,0148089), jika basis fungsi yang lain konstan.

11) $+0,09511318 * BF10 = +0,09511318 * h(72,8313 - X_7)$

$$+0,09511318 * h(72,8313 - X_7) = \begin{cases} (72,8313 - X_7); X_7 < 72,8313 \\ 0; X_7 \ge 72,8313 \end{cases}$$

Artinya, untuk kabupaten/kota yang memiliki persentase rumah tangga mengikuti KB aktif kurang dari 72,8313%, apabila rumah tangga mengikuti KB aktif bertambah 1% maka jumlah kematian ibu akan meningkat sebesar *exp*(0,09511318), jika basis fungsi yang lain konstan.

12) $-0,254227 * BF11 = -0,254227 * h(X_7 - 72,8313)$

$$-0,254227 * h(X_7 - 72,8313) = \begin{cases} (X_7 - 72,8313); X_7 > 72,8313 \\ 0; X_7 \le 72,8313 \end{cases}$$

Artinya, untuk kabupaten/kota yang memiliki persentase rumah tangga mengikuti KB aktif lebih dari 72,8313%, apabila rumah tangga mengikuti KB aktif bertambah 1% maka jumlah kematian ibu akan menurun sebesar *exp*(0,254227), jika basis fungsi yang lain konstan.

13) $-1,562888 * BF6 * X_7 = -1,562888 * h(X_3 - 98,778) * X_7$

$$-1,562888 * h(X_3 - 98,778) * X_7 = \begin{cases} h(X_3 - 98,778); X_3 > 98,778 \\ X_7 > 0 \\ 0; X_3 \le 98,778, X_7 \le 0 \end{cases}$$

Artinya, untuk kabupaten/kota yang memiliki persentase pemberian vitamin A pada ibu nifas lebih dari 98,778% dan persentase rumah tangga mengikuti KB aktif lebih dari 0% , apabila pemberian vitamin A pada ibu nifas dan rumah tangga mengikuti KB aktif bertambah 1% maka jumlah kematian ibu akan menurun sebesar *exp*(1,562888), jika basis fungsi yang lain konstan.

14)
$$\begin{aligned} & -0,0386978 * h(X_1 - 97,2565) * BF5 \\ & = -0,03869788 * h(X_1 - 97,2565) * h(98,778 - X_3) \\ & = \begin{cases} h(X_1 - 97,2565); X_1 > 97,2565 \\ h(98,778 - X_3); X_3 < 98,778 \\ 0, ketika \rightarrow X_1 \le 98,778; X_3 \ge 98,778 \end{cases} \end{aligned}$$

Artinya, untuk kabupaten/kota yang memiliki persentase kunjungan ibu hamil K1 lebih dari 97,2565% dan persentae

pemberian vitamin A pada ibu nifas kurang dari 98,778%, apabila kunjungan ibu hamil K1 dan pemberian vitamin A pada ibu nifas bertambah 1% maka jumlah kematian ibu akan menurun sebesar *exp*(0,0386978), jika basis fungsi yang lain konstan.

15)
$$
\begin{aligned}
&-0,0640392 * BF1 * BF13 \\
&= -0,0640392 * h(98,6576 - X_1) * h(X_3 - 83,5462) \\
&= \begin{cases} h(98,6576 - X_1); X_1 < 98,6576 \\ h(X_3 - 83,5462); X_3 > 83,5362 \\ 0, ketika \rightarrow X_1 \geq 98,6576; X_3 \leq 83,5362 \end{cases}
\end{aligned}
$$

Artinya, untuk kabupaten/kota yang memiliki persentase kunjungan ibu hamil K1 kurang dari 98,6576% dan persentae pemberian vitamin A pada ibu nifas lebih dari 83,5362%, apabila kunjungan ibu hamil K1 dan pemberian vitamin A pada ibu nifas bertambah 1% maka jumlah kematian ibu akan menurun sebesar *exp*(0,0640392), jika basis fungsi yang lain konstan.

16)
$$
\begin{aligned}
&-0,2104967 * BF1 * BF14 \\
&= -0,2104967 * h(98,6576 - X_1) * h(83,5462 - X_3) \\
&= \begin{cases} h(98,6576 - X_1); X_1 < 98,6576 \\ h(83,5462 - X_3); X_3 < 83,5362 \\ 0, ketika \rightarrow X_1 \geq 98,6576; X_3 \geq 83,5362 \end{cases}
\end{aligned}
$$

Artinya, untuk kabupaten/kota yang memiliki persentase kunjungan ibu hamil K1 kurang dari 98,6576% dan persentae pemberian vitamin A pada ibu nifas kurang dari 83,5362%, apabila kunjungan ibu hamil K1 dan pemberian vitamin A pada ibu nifas bertambah 1% maka jumlah kematian ibu akan menurun sebesar *exp*(0,210496), jika basis fungsi yang lain konstan.

17)
$$
\begin{aligned}
&+0,01461118 * BF5 * BF15 \\
&= +0,01461118 * h(98,778 - X_3) * h(X_4 - 92,3872)
\end{aligned}
$$

$$= \begin{cases} h(98{,}778 - X_3); X_3 < 98{,}778 \\ h(X_4 - 92{,}3872); X_4 > 92{,}3872 \\ 0, ketika \rightarrow X_3 \geq 98{,}778; X_4 \leq 92{,}3872 \end{cases}$$

Artinya, untuk kabupaten/kota yang memiliki persentase pemberian vitamin A pada ibu nifas kurang dari 98,778% dan persentase persalinan ditolong tenaga kesehatan lebih dari 92,3872%, apabila pemberian vitamin A pada ibu nifas dan persalinan ditolong tenaga kesehatan bertambah 1% maka jumlah kematian ibu akan meningkat sebesar *exp*(0,01461118), jika basis fungsi yang lain konstan.

18)
$$+0{,}01772304 * BF5 * BF16$$
$$= +0{,}01772304 * h(98{,}778 - X_3) * h(92{,}3872 - X_4)$$
$$= \begin{cases} h(98{,}778 - X_3); X_3 < 98{,}778 \\ h(92{,}3872 - X_4); X_4 < 92{,}3872 \\ 0, ketika \rightarrow X_3 \geq 98{,}778; X_4 \geq 92{,}3872 \end{cases}$$

Artinya, untuk kabupaten/kota yang memiliki persentase pemberian vitamin A pada ibu nifas kurang dari 98,778% dan persentase persalinan ditolong tenaga kesehatan kurang dari 92,3872%, apabila pemberian vitamin A pada ibu nifas dan persalinan ditolong tenaga kesehatan bertambah 1% maka jumlah kematian ibu akan meningkat sebesar *exp*(0,01772304), jika basis fungsi yang lain konstan.

19)
$$-0{,}01690982 * BF17 * BF8$$
$$= -0{,}01690982 * h(95{,}3338 - X_4) * h(97{,}9622 - X_6)$$
$$= \begin{cases} h(95{,}3338 - X_4); X_4 < 95{,}3338 \\ h(97{,}9622 - X_6); X_6 < 97{,}9622 \\ 0, ketika \rightarrow X_4 \geq 95{,}3338; X_6 \geq 97{,}9622 \end{cases}$$

Artinya, untuk kabupaten/kota yang memiliki persentase persalinan ditolong tenaga kesehatan kurang dari 95,3338% dan persentase penanganan komplikasi kebidanan kurang dari 97,9622%, apabila persalinan ditolong tenaga kesehatan dan penanganan komplikasi kebidanan bertambah 1% maka jumlah

kematian ibu akan menurun sebesar *exp*(0,01690982), jika basis fungsi yang lain konstan.

20)
$$
\begin{aligned}
&+0,00043042 * BF18 * BF8 \\
&= +0,00043042 * h\left(X_4 - 95,3338\right) * h\left(97,9622 - X_6\right) \\
&= \begin{cases} h\left(X_4 - 95,3338\right); X_4 > 95,3338 \\ h\left(97,9622 - X_6\right); X_6 < 97,9622 \\ 0, ketika \rightarrow X_4 \le 95,3338; X_6 \ge 97,9622 \end{cases}
\end{aligned}
$$

Artinya, untuk kabupaten/kota yang memiliki persentase persalinan ditolong tenaga kesehatan lebih dari 95,3338% dan persentase penanganan komplikasi kebidanan kurang dari 97,9622%, apabila persalinan ditolong tenaga kesehatan dan penanganan komplikasi kebidanan bertambah 1% maka jumlah kematian ibu akan meningkat sebesar *exp*(0,00043042), jika basis fungsi yang lain konstan.

21)
$$
\begin{aligned}
&+0,00601668 * BF19 * BF11 \\
&= +0,00601668 * h\left(91,5021 - X_5\right) * h\left(X_7 - 72,8313\right) \\
&= \begin{cases} h\left(91,5021 - X_5\right); X_5 < 91,5021 \\ h\left(X_7 - 72,8313\right); X_7 > 72,8313 \\ 0, ketika \rightarrow X_5 \ge 91,5021; X_7 \le 72,8313 \end{cases}
\end{aligned}
$$

Artinya, untuk kabupaten/kota yang memiliki persentase pemberian tablet Fe3 pada ibu hamil kurang dari 91,5021 % dan persentase rumah tangga yang mengikuti KB aktif lebih dari 72,8313%, apabila pemberian tablet Fe3 pada ibu hamil dan rumah tangga yang mengikuti KB bertambah 1% maka jumlah kematian ibu akan meningkat sebesar *exp*(0,00601668), jika basis fungsi yang lain konstan.

22)
$$
\begin{aligned}
&+0,08568682 * BF20 * BF11 \\
&= +0,08568682 * h\left(X_5 - 91,5021\right) * h\left(X_7 - 72,8313\right) \\
&= \begin{cases} h\left(X_5 - 91,5021\right); X_5 > 91,5021 \\ h\left(X_7 - 72,8313\right); X_7 > 72,8313 \\ 0, ketika \rightarrow X_5 \le 91,5021; X_7 \le 72,8313 \end{cases}
\end{aligned}
$$

Artinya, untuk kabupaten/kota yang memiliki persentase pemberian tablet Fe3 pada ibu hamil lebih dari 91,5021 % dan persentase rumah tangga yang mengikuti KB aktif lebih dari 72,8313%, apabila pemberian tablet Fe3 pada ibu hamil dan rumah tangga yang mengikuti KB bertambah 1% maka jumlah kematian ibu akan meningkat sebesar *exp*(0,08568682), jika basis fungsi yang lain konstan.

23)
$$
\begin{aligned}
&-0,05511934 * BF21 * BF10 \\
&= -0,05511934 * h(89,6465 - X_6) * h(72,8313 - X_7) \\
&= \begin{cases} h(89,6465 - X_6); X_6 < 89,6465 \\ h(72,8313 - X_7); X_7 < 72,8313 \\ 0, ketika \rightarrow X_6 \geq 89,6465; X_7 \geq 72,8313 \end{cases}
\end{aligned}
$$

Artinya, untuk kabupaten/kota yang memiliki persentase penanganan komplikasi kebidanan kurang dari 89,6465% dan persentase rumah tangga yang mengikuti KB aktif kurang dari 72,8313%, apabila penanganan komplikasi kebidanan dan rumah tangga yang mengikuti KB bertambah 1% maka jumlah kematian ibu akan menurun sebesar *exp*(0,05511934), jika basis fungsi yang lain konstan.

24)
$$
\begin{aligned}
&-0,1585744 * BF22 * BF10 \\
&= -0,1585744 * h(X_6 - 89,6465) * h(72,8313 - X_7) \\
&= \begin{cases} h(X_6 - 89,6465); X_6 > 89,6465 \\ h(72,8313 - X_7); X_7 < 72,8313 \\ 0, ketika \rightarrow X_6 \leq 89,6465; X_7 \geq 72,8313 \end{cases}
\end{aligned}
$$

Artinya, untuk kabupaten/kota yang memiliki persentase penanganan komplikasi kebidanan lebih dari 89,6465% dan persentase rumah tangga yang mengikuti KB aktif kurang dari 72,8313%, apabila penanganan komplikasi kebidanan dan rumah tangga yang mengikuti KB bertambah 1% maka jumlah kematian ibu akan menurun sebesar *exp*(0,1585744), jika basis fungsi yang lain konstan.

Tidak semua variabel prediktor yang berpengaruh signifikan terhadap model. Berdasarkan *output* R, dapat diketahui bahwa tiga

variabel prediktor yang paling berpengaruh terhadap model berdasarkan tiga kriteria yaitu *nsubset*, GCV, dan RSS adalah variabel persentase ibu nifas mendapat vitamin A, persentase peserta KB aktif, dan persentase kunjungan ibu hamil K4..

BAB V
KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan analisis yang telah dilakukan, diperoleh kesimpulan sebagai berikut.

1. Tahun 2018, rata-rata jumlah kematian ibu di Jawa Timur sebesar 13,737. Nilai varians jumlah kematian ibu sebesar 82,253 yang artinya, data jumlah kematian ibu di setiap kabupaten/kota cukup beragam. Jumlah kematian ibu terendah adalah sebesar 0, yang artinya tidak ada kematian ibu di Kota Madiun dan Kota Batu, sedangkan jumlah kematian ibu tertinggi adalah sebesar 41 kematian ibu yang terjadi di Kabupaten Jember. Pola hubungan antara jumlah kematian ibu di Jawa Timur dengan variabel-variabel yang diduga berpengaruh tidak membentuk pola tertentu, sehingga pemodelan menggunakan pendekatan nonparametrik *spline*.
2. Pengujian equidispersi dengan uji Khi Kuadrat Pearson dan *software* R menghasilkan kesimpulan terjadinya overdispersi pada data, sehingga metode *generalized poisson* cocok diterapkan. Pola data tidak tertentu, variabel prediktor lebih dari tiga, dan terjadi overdispersi membuat metode MAGPRS cocok digunakan pada penelitian ini. Model terbaik yang digunakan untuk memodelkan jumlah kematian ibu di Jawa Timur tahun 2018 ialah model MAGPRS dengan BF=28, MI=2, dan MO=2. Setelah dilakukan *backward stepwise*, fungsi basis dari model tersebut menjadi 24, dimana 24 fungsi basis tersebut seluruhnya signifikan terhadap model sesuai hasil uji parsial. Variabel prediktor yang paling berpengaruh terhadap model secara berurutan adalah variabel persentase ibu nifas mendapat vitamin A, persentase peserta aktif KB, dan persentase kunjungan ibu hamil K4.

5.2 Saran

Saran yang dapat direkomendasikan untuk penelitian selanjutnya adalah lebih mengkaji beberapa faktor penduga penyebab jumlah kematian ibu sehingga diharapkan mendapat model yang lebih baik. Bagi pemerintah, sebaiknya segera membuat kebijakan untuk menurunkan angka kematian ibu, seperti membuat program-program yang efektif mencegah kenaikan angka kematian.

DAFTAR PUSTAKA

Agresti, A. (2002). *Categorical Data Analysis.* United States of America: John Wiley and Sons Inc.

ASEAN Secretariat, T. (2017). *ASEAN Statistical Report on Millennium Development Goals.* Jakarta: Eu-ASEAN Compass.

BPS. (2020, Januari 15). *Angka Kematian Ibu (AKI)*. Retrieved from Sirusa BPS: https://sirusa.bps.go.id/sirusa/index.php/indikator/80

Cameron, A., & Trivedi, P. (1998). *Regression Analysis of Count Data*. Cambridge : Cambridge University Press.

Eubank, R. (1999). *Spline Smoothing and Nonparametric Regression.* New York: Mecel Deker.

Famoye, A., Wulu, J., & Sigh, K. (2004). On the Generalized Poisson Regression Model with an Application to Accident Data. *Journal of Data Science, Vol. 2, No. 2*, hal 287-295.

Friedman, J. (1991). Multivariate Adaptive Regression Spline (with discucssion). *Annual Statistics*, hal 191-141.

Friedman, J., & Silverman, B. (1989). Flexible Parsimory Smoothing and Additive Modeling, Technometrics. *Journal Technometrics, Vol 3 No 1*, hal 3-21.

Gujarati, D. N. (2003). *Basic Econometrics (Fourth ed)*. Gary Burke.

Hidayati, S. (2019). *Penaksiran Parameter dan Statistik Uji Model Multivariate Adaptive Generalized Poisson Regression Spline pada Kasus Jumlah Penderita Ispa pada Bayi Di Surabaya Tahun 2017.* Surabaya: Departemen Statistika ITS.

Hogg, R. V., McKean, J. W., & Craig, A. T. (2019). *Introduction to Mathematical Statistics 8 th ed.* Michigan: Pearson Eucation, Inc.

Khotimah, K. (2016). *Pemodelan Regresi Panel terhadap Faktor-Faktor yang Mempengaruhi Angka Kematian Ibu di Provinsi Jawa Timur.* Surabaya: Jurusan Statistika ITS.

McCarthy, J., & Maine, D. (1992). A Frame fo Analyzing the Determinants of Maternal Mortality. *Study in Family Planing. Vol 23, No 1*, hal 23-33.

Melliana, A., Setyorini, Y., Eko, H., Rosi, S., & Purhadi. (2013). The Comparison Of Generalized Poisson Regression And Negative Binomial Reression Methods In Overcoming Overdispersion. *Internationsl Journal Of Scientific & Technology Research Volume 2 Issue 8*, 255-258.

Mochtar, R. (1998). *Sinopsis Obstetri, Obstetri Sosial Edisi ke Dua.* Jakarta: EGC.

Mood, A., Graybill, F., & Boes, D. (1974). *Introduction to The Theory of Statistics Third Edition.* Singapura: McGraw-Hill.

Nahriyah, L. (2017). *Bootstrap Aggregating Multivariate Adaptive Regression Splines (Bagging Mars) untuk Klasifikasi Pasien Hiv/Aids Di Kabupaten Pasuruan.* Surabaya: Departemen Statistika ITS.

Otok, B., Eta, D., & Sita. (2014). Pendekatan Multivariate Adaptive Regression SPLINES (MARS) pada Pemodelan Penduduk Miskin di Indonesia Tahun 2008-2012. *Prosiding Seminar Nasional Matematika*, 175-191.

Otok, B., Hidayati, S., & Purhadi. (2019). Multivariate Adaptive Generalized Poisson Regression Spline (MAGPRS) on the number of acute respiratory infection infants. *Journal of Physics: Conference Series 1397*, hal 1-7.

SDGs, S. (2020, Januari 13). *Tujuan 03*. Retrieved from Sustainable Development Goals: https://www.sdg2030indonesia.org

Walpole, R. E., Myers, R. H., Myers, S. L., & Ye, K. (2016). *Probability & Statistics for Engineers & Scientists Ninth Edition Global.* England: Prentice Hall.

Wang, W., & Famoye, F. (1997). Modelling Household Fertility Decisions with Generalized Poisson Regression. *Journal of Population Economics, Vol 10, No.3*, hal 273-283.

Wardani, B. I. (2015). *Pemodelan Faktor-Faktor yang Mempengaruhi Jumlah Kematian Ibu di Jawa Timur Tahun 2013 Menggunakan Regresi Binomial Negatif*. Surabaya: Jurusan Statistika ITS.

WHO. (2004, Januari 15). *Health Statistics and Information Systems*. Retrieved from World Health Organization: https://www.who.int/healthinfo/statistics/indmaternalmortality/en/

World Commission, O. E. (1987). *Our Common Future*. United Nation: Oxford University Press.

(Halaman ini sengaja dikosongkan)

LAMPIRAN

Lampiran 1. Data Jumlah Kematian Ibu di Jawa Timur Tahun 2018 dan Faktor-Faktor yang Diduga Berpengaruh

Kabupaten/Kota	Y	X_1	X_2	X_3	X_4	X_5	X_6	X_7
Kabupaten Pacitan	3	94,0	90,3	83,6	86,5	81,79	99,2	70,20
Kabupaten Ponorogo	9	96,1	83,7	68,3	89,0	79,48	112,8	73,61
Kabupaten Trenggalek	7	95,0	84,1	90,5	91,9	87,98	98,4	72,45
Kabupaten Tulungagung	18	96,9	91,1	87,1	92,6	88,15	85,1	73,70
Kabupaten Blitar	10	92,8	84,4	83,5	87,2	84,73	98,0	83,69
Kabupaten Kediri	17	96,4	91,5	86,4	92,4	90,17	88,4	75,87
Kabupaten Malang	17	100,5	98,4	99,4	99,7	98,62	87,5	71,26
Kabupaten Lumajang	16	107,4	94,4	96,1	102,3	95,79	119,4	80,97
Kabupaten Jember	41	101,7	80,8	90,9	94,0	94,05	136,5	88,85
Kabupaten Banyuwangi	24	99,1	94,2	94,7	98,3	94,48	91,3	69,36
Kabupaten Bondowoso	19	105,8	86,7	97,3	100,0	87,99	147,9	80,58
Kabupaten Situbondo	13	102,4	84,1	98,0	97,8	86,16	116,4	86,07
Kabupaten Probolinggo	12	102,1	87,5	97,3	100,1	88,94	107,1	73,78
Kabupaten Pasuruan	28	100,5	93,7	96,3	99,3	93,42	74,3	71,71
Kabupaten Sidoarjo	23	100,0	100,0	95,4	97,0	95,73	98,7	76,37
Kabupaten Mojokerto	19	99,7	88,3	84,1	94,7	85,39	139,1	86,64
Kabupaten Jombang	18	97,8	91,0	87,5	93,5	90,99	100,5	75,56
Kabupaten Nganjuk	12	88,9	79,6	83,3	89,1	78,48	83,6	83,34
Kabupaten Madiun	6	98,8	91,3	91,2	92,3	90,85	93,4	79,45
Kabupaten Magetan	13	105,0	96,0	94,5	98,2	96,00	106,0	79,78
Kabupaten Ngawi	12	96,2	89,3	77,2	92,3	73,14	107,4	76,71
Kabupaten Bojonegoro	27	100,4	87,0	93,0	98,4	84,45	100,0	73,59
Kabupaten Tuban	8	100,0	92,9	93,6	96,1	91,50	85,8	79,44
Kabupaten Lamongan	8	100,0	99,7	100,0	100,0	99,68	95,2	70,15
Kabupaten Gresik	20	96,5	88,5	89,7	92,9	89,00	85,2	71,59
Kabupaten Bangkalan	11	92,4	80,4	81,0	93,0	75,51	74,3	71,15
Kabupaten Sampang	15	105,4	84,5	97,8	99,8	84,27	94,9	82,38
Kabupaten Pamekasan	21	104,8	92,8	80,6	100,3	89,87	109,7	71,46
Kabupaten Sumenep	12	105,1	93,5	92,9	101,4	89,64	106,4	75,01
Kota Kediri	2	98,7	93,2	86,2	95,3	90,39	51,5	68,99
Kota Blitar	5	92,0	83,6	87,9	87,0	85,48	89,6	74,91
Kota Malang	10	100,4	94,6	77,8	94,6	91,82	106,3	74,99
Kota Probolinggo	4	100,0	95,5	96,8	95,8	97,55	93,8	72,90
Kota Pasuruan	10	97,3	90,4	96,1	94,1	90,92	77,6	73,23
Kota Mojokerto	1	100,1	98,4	98,3	99,9	98,40	96,8	72,83
Kota Madiun	0	100,0	100,0	98,9	100,0	99,96	100,0	67,70
Kota Surabaya	31	100,1	99,0	98,8	97,7	99,96	94,5	79,00
Kota Batu	0	96,1	90,9	93,5	94,6	90,95	99,0	71,72

Lampiran 2. *Output* R Uji Equidispersi

```
data:  data_dis
z = 4.2498, p-value = 1.07e-05
alternative hypothesis: true dispersion is greater than 1
sample estimates:
dispersion
  4.241606
```

Lampiran 3. *Output* Estimasi Parameter MAGPRS

	nilai_nk_magprs	nilai_degree_magprs	nilai_minspan_magprs	nilai_gcv_magprs	nilai_rsq_magprs
1	14	1	0	0.0008814887	0.8278344
2	14	1	1	0.0004777033	0.9066987
3	14	1	2	0.0005037303	0.9016153
4	14	1	3	0.0004956323	0.9031969
5	14	2	0	0.0007525405	0.8530196
6	14	2	1	0.0005328630	0.8959253
7	14	2	2	0.0004221314	0.9175526
8	14	2	3	0.0004933685	0.9036391
9	14	3	0	0.0007525405	0.8530196
10	14	3	1	0.0005387701	0.8947716
11	14	3	2	0.0004221314	0.9175526
12	14	3	3	0.0004933685	0.9036391
13	21	1	0	0.0007930928	0.8450992
14	21	1	1	0.0002809943	0.9451184
15	21	1	2	0.0002484324	0.9514781
16	21	1	3	0.0003525152	0.9311494
17	21	2	0	0.0006304153	0.8768721
18	21	2	1	0.0003841625	0.9249683
19	21	2	2	0.0002062586	0.9597152
20	21	2	3	0.0003653128	0.9286499
21	21	3	0	0.0006304153	0.8768721
22	21	3	1	0.0002962472	0.9421393
23	21	3	2	0.0002062586	0.9597152
24	21	3	3	0.0003653128	0.9286499
25	28	1	0	0.0006211283	0.8786860
26	28	1	1	0.0002091195	0.9591564
27	28	1	2	0.0001343070	0.9737682
28	28	1	3	0.0003334408	0.9348749
29	28	2	0	0.0002530766	0.9505710
30	28	2	1	0.0002423717	0.9526618
31	28	2	2	0.0001197584	0.9766097
32	28	2	3	0.0002450882	0.9521313
33	28	3	0	0.0002530766	0.9505710
34	28	3	1	0.0002737257	0.9465380
35	28	3	2	0.0001205716	0.9764509
36	28	3	3	0.0002450882	0.9521313

Lampiran 4. *Output* Matriks Bobot WLS

```
             [,1]
 [1,] 1.478205e-03
 [2,] 6.078602e-05
 [3,] 3.972211e-04
 [4,] 8.812075e-06
 [5,] 4.031453e-05
 [6,] 1.618760e-05
 [7,] 1.505797e-05
 [8,] 2.187852e-05
 [9,] 7.661356e-07
[10,] 4.782838e-06
[11,] 6.157496e-06
[12,] 2.230713e-05
[13,] 3.177873e-05
[14,] 2.290218e-06
[15,] 6.473987e-06
[16,] 1.243594e-05
[17,] 1.587570e-05
[18,] 3.368748e-05
[19,] 7.533015e-05
[20,] 3.617499e-05
[21,] 4.258067e-05
[22,] 3.197083e-06
[23,] 1.301781e-04
[24,] 9.544416e-05
[25,] 5.455675e-06
[26,] 3.463885e-05
[27,] 1.246937e-05
[28,] 5.189657e-06
[29,] 2.918726e-05
[30,] 1.963518e-03
[31,] 5.120720e-04
[32,] 5.269146e-05
[33,] 6.855587e-04
[34,] 6.722002e-05
[35,] 9.386207e-03
[36,] 3.618462e+00
[37,] 1.023061e-06
[38,] 2.116904e-03
```

Lampiran 5. *Output* BHHH Parameter Dispersi

```
=====================================
Estimasi Omega Kecil
=====================================
 estimate std.error z_value
teta  -0.3667592   0.02713143   -13.51787
=====================================
```

Lampiran 6. *Output* Hasil Uji Serentak

```
================================================================
 Uji Serentak MAGPRS
================================================================
G kuadrat Daerah_Kritis Kesimpulan
1793.918   35.17246   Tolak H0 dengan alfa 5%
================================================================
```

Lampiran 7. *Output* Estimasi Parameter dan Hasil Uji Parsial

```
Call:
lm(formula = Ypred_magprs ~ bx_magprs[, -1])

Residuals:
       Min         1Q     Median         3Q        Max
-5.940e-15 -1.572e-15 -3.422e-16  1.222e-15  1.207e-14

Coefficients:
                                          Estimate Std. Error    t value Pr(>|t|)
(Intercept)                               2.106e-02  7.955e-15  2.647e+12   <2e-16 ***
bx_magprs[, -1]h(X7-72.8313)             -2.542e-01  5.852e-16 -4.344e+14   <2e-16 ***
bx_magprs[, -1]h(72.8313-X7)              9.511e-02  1.880e-15  5.059e+13   <2e-16 ***
bx_magprs[, -1]h(X3-98.778)               1.147e+02  6.568e-13  1.747e+14   <2e-16 ***
bx_magprs[, -1]h(98.778-X3)               1.905e-01  5.393e-16  3.533e+14   <2e-16 ***
bx_magprs[, -1]h(X1-98.6576)              1.482e-01  8.318e-16  1.782e+14   <2e-16 ***
bx_magprs[, -1]h(98.6576-X1)             -3.849e-01  1.310e-15 -2.938e+14   <2e-16 ***
bx_magprs[, -1]h(X2-98.3972)             -1.679e+00  3.688e-15 -4.553e+14   <2e-16 ***
bx_magprs[, -1]h(98.3972-X2)              2.464e-01  4.485e-16  5.494e+14   <2e-16 ***
bx_magprs[, -1]h(98.6576-X1)*h(X3-83.5462) -6.404e-02  1.666e-16 -3.844e+14   <2e-16 ***
bx_magprs[, -1]h(98.6576-X1)*h(83.5462-X3) -2.105e-01  3.370e-16 -6.245e+14   <2e-16 ***
bx_magprs[, -1]h(X6-89.6465)*h(72.8313-X7) -1.586e-01  2.239e-16 -7.081e+14   <2e-16 ***
bx_magprs[, -1]h(89.6465-X6)*h(72.8313-X7) -5.512e-02  1.118e-16 -4.931e+14   <2e-16 ***
bx_magprs[, -1]h(X1-97.2565)*h(98.778-X3)  -3.870e-02  2.359e-16 -1.641e+14   <2e-16 ***
bx_magprs[, -1]h(X6-97.9622)              1.481e-02  1.130e-16  1.310e+14   <2e-16 ***
bx_magprs[, -1]h(97.9622-X6)              1.045e-01  3.258e-16  3.207e+14   <2e-16 ***
bx_magprs[, -1]h(X3-98.778)*X7           -1.563e+00  9.324e-15 -1.676e+14   <2e-16 ***
bx_magprs[, -1]h(X5-91.5021)*h(X7-72.8313)  8.569e-02  1.401e-16  6.114e+14   <2e-16 ***
bx_magprs[, -1]h(91.5021-X5)*h(X7-72.8313)  6.017e-03  6.278e-17  9.584e+13   <2e-16 ***
bx_magprs[, -1]h(X4-95.3338)*h(97.9622-X6)  4.304e-04  8.001e-17  5.380e+12   <2e-16 ***
bx_magprs[, -1]h(95.3338-X4)*h(97.9622-X6) -1.691e-02  1.075e-16 -1.573e+14   <2e-16 ***
bx_magprs[, -1]h(X5-90.946)              -5.784e-02  9.460e-16 -6.115e+13   <2e-16 ***
bx_magprs[, -1]h(98.778-X3)*h(X4-92.3872)   1.461e-02  1.888e-16  7.738e+13   <2e-16 ***
bx_magprs[, -1]h(98.778-X3)*h(92.3872-X4)   1.772e-02  5.567e-17  3.184e+14   <2e-16 ***
---
Signif. codes:  0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1

Residual standard error: 5.007e-15 on 14 degrees of freedom
Multiple R-squared:      1,         Adjusted R-squared:      1
F-statistic: 3.613e+29 on 23 and 14 DF,  p-value: < 2.2e-16

Call: earth(formula=Y~X1+X2+X3+X4+X5+X6+X7, data=data, weights=weighted, wp=NULL,
glm=list(family=poisson), degree=2, nk=28, minspan=2, endspan=2,
            penalty=-1)

GLM coefficients
                                    Y
(Intercept)                  0.021058
h(98.6576-X1)               -0.384924
h(X1-98.6576)                0.148202
h(98.3972-X2)                0.246444
h(X2-98.3972)               -1.679300
h(98.778-X3)                 0.190538
h(X3-98.778)               114.745626
h(X5-90.946)                -0.057841
h(97.9622-X6)                0.104468
h(X6-97.9622)                0.014809
```

```
h(72.8313-X7)                  0.095113
h(X7-72.8313)                 -0.254227
h(X3-98.778) * X7             -1.562888
h(X1-97.2565) * h(98.778-X3)  -0.038698
h(98.6576-X1) * h(X3-83.5462) -0.064039
h(98.6576-X1) * h(83.5462-X3) -0.210497
h(98.778-X3) * h(X4-92.3872)   0.014611
h(98.778-X3) * h(92.3872-X4)   0.017723
h(95.3338-X4) * h(97.9622-X6) -0.016910
h(X4-95.3338) * h(97.9622-X6)  0.000430
h(91.5021-X5) * h(X7-72.8313)  0.006017
h(X5-91.5021) * h(X7-72.8313)  0.085687
h(89.6465-X6) * h(72.8313-X7) -0.055119
h(X6-89.6465) * h(72.8313-X7) -0.158574

GLM (family poisson, link log):
 nulldev df       dev df   devratio     AIC iters converged
 0.41901 37 0.0064355 14      0.985   48.04    11         1

Earth selected 24 of 24 terms, and 7 of 7 predictors
Termination condition: Reached nk 28
Importance: X3, X7, X2, X1, X6, X5, X4
Weights: 0.001478205, 6.078602e-05, 0.0003972211, 8.812075e-06, 4.031453e-05, 1.61876e-05,
1.505797e-05, 2.187852e-05, 7.661356e-07, 4.7828...
Number of terms at each degree of interaction: 1 11 12
Earth GCV 0.0001197584    RSS 0.004550819    GRSq 0.9766097    RSq 0.9766097
```

Lampiran 8. *Syntax* Uji Equidispersi

```
library(readxl)
library (car)
library (lmtest)
library (zoo)
library (AER)
data <- read_excel("E:/ITS/8/Data TA Euodia.xlsx")
View(data)
data_dis <- glm(Y~X1+X2+X3+X4+X5+X6+X7,data = data, family =
poisson)
data_dis
dispersiontest(data_dis)
summary(data_dis)
```

Lampiran 9. *Syntax* Estimasi Parameter MAGPRS

```
#---------Program MAGPRS-----------------------------------------
library(earth)
#MARS
PsMars14.1.0 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=14,
minspan=0,endspan=0, degree=1, penalty=-1,glm=list(family=poisson))
PsMars14.1.1 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=14,
minspan=1,endspan=1, degree=1, penalty=-1,glm=list(family=poisson))
PsMars14.1.2 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=14,
minspan=2,endspan=2, degree=1, penalty=-1,glm=list(family=poisson))
PsMars14.1.3 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=14,
minspan=3,endspan=3, degree=1, penalty=-1,glm=list(family=poisson))

PsMars14.2.0 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=14,
minspan=0,endspan=0, degree=2, penalty=-1,glm=list(family=poisson))
```

```
PsMars14.2.1 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=14,
minspan=1,endspan=1, degree=2, penalty=-1,glm=list(family=poisson))
PsMars14.2.2 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=14,
minspan=2,endspan=2, degree=2, penalty=-1,glm=list(family=poisson))
PsMars14.2.3 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=14,
minspan=3,endspan=3, degree=2, penalty=-1,glm=list(family=poisson))

PsMars14.3.0 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=14,
minspan=0,endspan=0, degree=3, penalty=-1,glm=list(family=poisson))
PsMars14.3.1 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=14,
minspan=1,endspan=1, degree=3, penalty=-1,glm=list(family=poisson))
PsMars14.3.2 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=14,
minspan=2,endspan=2, degree=3, penalty=-1,glm=list(family=poisson))
PsMars14.3.3 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=14,
minspan=3,endspan=3, degree=3, penalty=-1,glm=list(family=poisson))

PsMars21.1.0 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=21,
minspan=0,endspan=0, degree=1, penalty=-1,glm=list(family=poisson))
PsMars21.1.1 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=21,
minspan=1,endspan=1, degree=1, penalty=-1,glm=list(family=poisson))
PsMars21.1.2 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=21,
minspan=2,endspan=2, degree=1, penalty=-1,glm=list(family=poisson))
PsMars21.1.3 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=21,
minspan=3,endspan=3, degree=1, penalty=-1,glm=list(family=poisson))

PsMars21.2.0 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=21,
minspan=0,endspan=0, degree=2, penalty=-1,glm=list(family=poisson))
PsMars21.2.1 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=21,
minspan=1,endspan=1, degree=2, penalty=-1,glm=list(family=poisson))
PsMars21.2.2 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=21,
minspan=2,endspan=2, degree=2, penalty=-1,glm=list(family=poisson))
PsMars21.2.3 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=21,
minspan=3,endspan=3, degree=2, penalty=-1,glm=list(family=poisson))

PsMars21.3.0 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=21,
minspan=0,endspan=0, degree=3, penalty=-1,glm=list(family=poisson))
PsMars21.3.1 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=21,
minspan=1,endspan=1, degree=3, penalty=-1,glm=list(family=poisson))
PsMars21.3.2 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=21,
minspan=2,endspan=2, degree=3, penalty=-1,glm=list(family=poisson))
PsMars21.3.3 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=21,
minspan=3,endspan=3, degree=3, penalty=-1,glm=list(family=poisson))

PsMars28.1.0 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=28,
minspan=0,endspan=0, degree=1, penalty=-1,glm=list(family=poisson))
PsMars28.1.1 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=28,
minspan=1,endspan=1, degree=1, penalty=-1,glm=list(family=poisson))
PsMars28.1.2 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=28,
minspan=2,endspan=2, degree=1, penalty=-1,glm=list(family=poisson))
PsMars28.1.3 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=28,
minspan=3,endspan=3, degree=1, penalty=-1,glm=list(family=poisson))
```

```
PsMars28.2.0 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=28,
minspan=0,endspan=0, degree=2, penalty=-1,glm=list(family=poisson))
PsMars28.2.1 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=28,
minspan=1,endspan=1, degree=2, penalty=-1,glm=list(family=poisson))
PsMars28.2.2 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=28,
minspan=2,endspan=2, degree=2, penalty=-1,glm=list(family=poisson))
PsMars28.2.3 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=28,
minspan=3,endspan=3, degree=2, penalty=-1,glm=list(family=poisson))

PsMars28.3.0 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=28,
minspan=0,endspan=0, degree=3, penalty=-1,glm=list(family=poisson))
PsMars28.3.1 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=28,
minspan=1,endspan=1, degree=3, penalty=-1,glm=list(family=poisson))
PsMars28.3.2 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=28,
minspan=2,endspan=2, degree=3, penalty=-1,glm=list(family=poisson))
PsMars28.3.3 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=28,
minspan=3,endspan=3, degree=3, penalty=-1,glm=list(family=poisson))

#Nilai nk MARS
nilai_nk = c(PsMars14.1.0$nk, PsMars14.1.1$nk, PsMars14.1.2$nk,
PsMars14.1.3$nk,
             PsMars14.2.0$nk, PsMars14.2.1$nk, PsMars14.2.2$nk,
PsMars14.2.3$nk,
             PsMars14.3.0$nk, PsMars14.3.1$nk, PsMars14.3.2$nk,
PsMars14.3.3$nk,
             PsMars21.1.0$nk, PsMars21.1.1$nk, PsMars21.1.2$nk,
PsMars21.1.3$nk,
             PsMars21.2.0$nk, PsMars21.2.1$nk, PsMars21.2.2$nk,
PsMars21.2.3$nk,
             PsMars21.3.0$nk, PsMars21.3.1$nk, PsMars21.3.2$nk,
PsMars21.3.3$nk,
             PsMars28.1.0$nk, PsMars28.1.1$nk, PsMars28.1.2$nk,
PsMars28.1.3$nk,
             PsMars28.2.0$nk, PsMars28.2.1$nk, PsMars28.2.2$nk,
PsMars28.2.3$nk,
             PsMars28.3.0$nk, PsMars28.3.1$nk, PsMars28.3.2$nk,
PsMars28.3.3$nk)

#Nilai degree MARS
nilai_degree =
c(1,1,1,1,2,2,2,2,3,3,3,3,1,1,1,1,2,2,2,2,3,3,3,3,1,1,1,1,2,2,2,2,3,
3,3,3)

#Nilai Minspan MARS
nilai_minspan =
c(0,1,2,3,0,1,2,3,0,1,2,3,0,1,2,3,0,1,2,3,0,1,2,3,0,1,2,3,0,1,2,3,0,
1,2,3)

#Nilai GCV MARS
```

```
nilai_gcv = c(PsMars14.1.0$gcv, PsMars14.1.1$gcv, PsMars14.1.2$gcv,
PsMars14.1.3$gcv,
              PsMars14.2.0$gcv, PsMars14.2.1$gcv, PsMars14.2.2$gcv,
PsMars14.2.3$gcv,
              PsMars14.3.0$gcv, PsMars14.3.1$gcv, PsMars14.3.2$gcv,
PsMars14.3.3$gcv,
              PsMars21.1.0$gcv, PsMars21.1.1$gcv, PsMars21.1.2$gcv,
PsMars21.1.3$gcv,
              PsMars21.2.0$gcv, PsMars21.2.1$gcv, PsMars21.2.2$gcv,
PsMars21.2.3$gcv,
              PsMars21.3.0$gcv, PsMars21.3.1$gcv, PsMars21.3.2$gcv,
PsMars21.3.3$gcv,
              PsMars28.1.0$gcv, PsMars28.1.1$gcv, PsMars28.1.2$gcv,
PsMars28.1.3$gcv,
              PsMars28.2.0$gcv, PsMars28.2.1$gcv, PsMars28.2.2$gcv,
PsMars28.2.3$gcv,
              PsMars28.3.0$gcv, PsMars28.3.1$gcv, PsMars28.3.2$gcv,
PsMars28.3.3$gcv)

#Nilai RS MARS
nilai_rsq = c(PsMars14.1.0$rsq, PsMars14.1.1$rsq, PsMars14.1.2$rsq,
PsMars14.1.3$rsq,
              PsMars14.2.0$rsq, PsMars14.2.1$rsq, PsMars14.2.2$rsq,
PsMars14.2.3$rsq,
              PsMars14.3.0$rsq, PsMars14.3.1$rsq, PsMars14.3.2$rsq,
PsMars14.3.3$rsq,
              PsMars21.1.0$rsq, PsMars21.1.1$rsq, PsMars21.1.2$rsq,
PsMars21.1.3$rsq,
              PsMars21.2.0$rsq, PsMars21.2.1$rsq, PsMars21.2.2$rsq,
PsMars21.2.3$rsq,
              PsMars21.3.0$rsq, PsMars21.3.1$rsq, PsMars21.3.2$rsq,
PsMars21.3.3$rsq,
              PsMars28.1.0$rsq, PsMars28.1.1$rsq, PsMars28.1.2$rsq,
PsMars28.1.3$rsq,
              PsMars28.2.0$rsq, PsMars28.2.1$rsq, PsMars28.2.2$rsq,
PsMars28.2.3$rsq,
              PsMars28.3.0$rsq, PsMars28.3.1$rsq, PsMars28.3.2$rsq,
PsMars28.3.3$rsq)

data.frame(nilai_nk, nilai_degree, nilai_minspan, nilai_gcv,
nilai_rsq)
optimumGCVMars=cbind(nilai_nk, nilai_degree, nilai_minspan,
nilai_gcv)

#mengurutkan nilai GCV minimum
GCVmin1=optimumGCVMars[order(optimumGCVMars[,ncol(optimumGCVMars)]),
]
GCVmin1[1,]

bx <- model.matrix(PsMars28.2.1)
Ypred=predict(PsMars28.2.1)
```

```
lm.mod <- lm(Ypred ~ bx[,-1]) # -1 to drop intercept
summary(lm.mod)
summary(PsMars28.2.1)

#-----------------------------------------------------------------

#---------Matriks Bobot-----------------------------------------------
X=as.matrix(PsMars28.2.1$glm.coefficients)
C=as.matrix(exp(bx%*%X))
dispersi=4.241606
n=38
W=rep(NA,n)
for (i in 1:n)
{
  W[i]=1/(C[i]*(1+dispersi*C[i])^2)
}
weighted=as.matrix(W)
weighted

#----------Estimasi MAGPRS----------------------------------------
PsMagprs14.1.0 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=14,
minspan=0,endspan=0, degree=1, penalty=-1,glm=list(family=poisson),
weights = weighted, wp = NULL)
PsMagprs14.1.1 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=14,
minspan=1,endspan=1, degree=1, penalty=-1,glm=list(family=poisson),
weights = weighted, wp = NULL)
PsMagprs14.1.2 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=14,
minspan=2,endspan=2, degree=1, penalty=-1,glm=list(family=poisson),
weights = weighted, wp = NULL)
PsMagprs14.1.3 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=14,
minspan=3,endspan=3, degree=1, penalty=-1,glm=list(family=poisson),
weights = weighted, wp = NULL)

PsMagprs14.2.0 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=14,
minspan=0,endspan=0, degree=2, penalty=-1,glm=list(family=poisson),
weights = weighted, wp = NULL)
PsMagprs14.2.1 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=14,
minspan=1,endspan=1, degree=2, penalty=-1,glm=list(family=poisson),
weights = weighted, wp = NULL)
PsMagprs14.2.2 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=14,
minspan=2,endspan=2, degree=2, penalty=-1,glm=list(family=poisson),
weights = weighted, wp = NULL)
PsMagprs14.2.3 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=14,
minspan=3,endspan=3, degree=2, penalty=-1,glm=list(family=poisson),
weights = weighted, wp = NULL)

PsMagprs14.3.0 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=14,
minspan=0,endspan=0, degree=3, penalty=-1,glm=list(family=poisson),
weights = weighted, wp = NULL)
```

```
PsMagprs14.3.1 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=14,
minspan=1,endspan=1, degree=3, penalty=-1,glm=list(family=poisson),
weights = weighted, wp = NULL)
PsMagprs14.3.2 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=14,
minspan=2,endspan=2, degree=3, penalty=-1,glm=list(family=poisson),
weights = weighted, wp = NULL)
PsMagprs14.3.3 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=14,
minspan=3,endspan=3, degree=3, penalty=-1,glm=list(family=poisson),
weights = weighted, wp = NULL)

PsMagprs21.1.0 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=21,
minspan=0,endspan=0, degree=1, penalty=-1,glm=list(family=poisson),
weights = weighted, wp = NULL)
PsMagprs21.1.1 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=21,
minspan=1,endspan=1, degree=1, penalty=-1,glm=list(family=poisson),
weights = weighted, wp = NULL)
PsMagprs21.1.2 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=21,
minspan=2,endspan=2, degree=1, penalty=-1,glm=list(family=poisson),
weights = weighted, wp = NULL)
PsMagprs21.1.3 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=21,
minspan=3,endspan=3, degree=1, penalty=-1,glm=list(family=poisson),
weights = weighted, wp = NULL)

PsMagprs21.2.0 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=21,
minspan=0,endspan=0, degree=2, penalty=-1,glm=list(family=poisson),
weights = weighted, wp = NULL)
PsMagprs21.2.1 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=21,
minspan=1,endspan=1, degree=2, penalty=-1,glm=list(family=poisson),
weights = weighted, wp = NULL)
PsMagprs21.2.2 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=21,
minspan=2,endspan=2, degree=2, penalty=-1,glm=list(family=poisson),
weights = weighted, wp = NULL)
PsMagprs21.2.3 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=21,
minspan=3,endspan=3, degree=2, penalty=-1,glm=list(family=poisson),
weights = weighted, wp = NULL)

PsMagprs21.3.0 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=21,
minspan=0,endspan=0, degree=3, penalty=-1,glm=list(family=poisson),
weights = weighted, wp = NULL)
PsMagprs21.3.1 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=21,
minspan=1,endspan=1, degree=3, penalty=-1,glm=list(family=poisson),
weights = weighted, wp = NULL)
PsMagprs21.3.2 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=21,
minspan=2,endspan=2, degree=3, penalty=-1,glm=list(family=poisson),
weights = weighted, wp = NULL)
PsMagprs21.3.3 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=21,
minspan=3,endspan=3, degree=3, penalty=-1,glm=list(family=poisson),
weights = weighted, wp = NULL)
```

```
PsMagprs28.1.0 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=28,
minspan=0,endspan=0, degree=1, penalty=-1,glm=list(family=poisson),
weights = weighted, wp = NULL)
PsMagprs28.1.1 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=28,
minspan=1,endspan=1, degree=1, penalty=-1,glm=list(family=poisson),
weights = weighted, wp = NULL)
PsMagprs28.1.2 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=28,
minspan=2,endspan=2, degree=1, penalty=-1,glm=list(family=poisson),
weights = weighted, wp = NULL)
PsMagprs28.1.3 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=28,
minspan=3,endspan=3, degree=1, penalty=-1,glm=list(family=poisson),
weights = weighted, wp = NULL)

PsMagprs28.2.0 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=28,
minspan=0,endspan=0, degree=2, penalty=-1,glm=list(family=poisson),
weights = weighted, wp = NULL)
PsMagprs28.2.1 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=28,
minspan=1,endspan=1, degree=2, penalty=-1,glm=list(family=poisson),
weights = weighted, wp = NULL)
PsMagprs28.2.2 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=28,
minspan=2,endspan=2, degree=2, penalty=-1,glm=list(family=poisson),
weights = weighted, wp = NULL)
PsMagprs28.2.3 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=28,
minspan=3,endspan=3, degree=2, penalty=-1,glm=list(family=poisson),
weights = weighted, wp = NULL)

PsMagprs28.3.0 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=28,
minspan=0,endspan=0, degree=3, penalty=-1,glm=list(family=poisson),
weights = weighted, wp = NULL)
PsMagprs28.3.1 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=28,
minspan=1,endspan=1, degree=3, penalty=-1,glm=list(family=poisson),
weights = weighted, wp = NULL)
PsMagprs28.3.2 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=28,
minspan=2,endspan=2, degree=3, penalty=-1,glm=list(family=poisson),
weights = weighted, wp = NULL)
PsMagprs28.3.3 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=28,
minspan=3,endspan=3, degree=3, penalty=-1,glm=list(family=poisson),
weights = weighted, wp = NULL)

#Nilai nk MAGPRS
nilai_nk_magprs = c(PsMagprs14.1.0$nk, PsMagprs14.1.1$nk,
PsMagprs14.1.2$nk, PsMagprs14.1.3$nk,
                    PsMagprs14.2.0$nk, PsMagprs14.2.1$nk,
PsMagprs14.2.2$nk, PsMagprs14.2.3$nk,
                    PsMagprs14.3.0$nk, PsMagprs14.3.1$nk,
PsMagprs14.3.2$nk, PsMagprs14.3.3$nk,
                    PsMagprs21.1.0$nk, PsMagprs21.1.1$nk,
PsMagprs21.1.2$nk, PsMagprs21.1.3$nk,
                    PsMagprs21.2.0$nk, PsMagprs21.2.1$nk,
PsMagprs21.2.2$nk, PsMagprs21.2.3$nk,
```

```
                    PsMagprs21.3.0$nk, PsMagprs21.3.1$nk,
PsMagprs21.3.2$nk, PsMagprs21.3.3$nk,
                    PsMagprs28.1.0$nk, PsMagprs28.1.1$nk,
PsMagprs28.1.2$nk, PsMagprs28.1.3$nk,
                    PsMagprs28.2.0$nk, PsMagprs28.2.1$nk,
PsMagprs28.2.2$nk, PsMagprs28.2.3$nk,
                    PsMagprs28.3.0$nk, PsMagprs28.3.1$nk,
PsMagprs28.3.2$nk, PsMagprs28.3.3$nk)

#Nilai degree MAGPRS
nilai_degree_magprs =
c(1,1,1,1,2,2,2,2,3,3,3,3,1,1,1,1,2,2,2,2,3,3,3,3,1,1,1,1,2,2,2,2,3,
3,3,3)

#Nilai Minspan MAGPRS
nilai_minspan_magprs =
c(0,1,2,3,0,1,2,3,0,1,2,3,0,1,2,3,0,1,2,3,0,1,2,3,0,1,2,3,0,1,2,3,0,
1,2,3)

#Nilai GCV MAGPRS
nilai_gcv_magprs =  c(PsMagprs14.1.0$gcv, PsMagprs14.1.1$gcv,
PsMagprs14.1.2$gcv, PsMagprs14.1.3$gcv,
                      PsMagprs14.2.0$gcv, PsMagprs14.2.1$gcv,
PsMagprs14.2.2$gcv, PsMagprs14.2.3$gcv,
                      PsMagprs14.3.0$gcv, PsMagprs14.3.1$gcv,
PsMagprs14.3.2$gcv, PsMagprs14.3.3$gcv,
                      PsMagprs21.1.0$gcv, PsMagprs21.1.1$gcv,
PsMagprs21.1.2$gcv, PsMagprs21.1.3$gcv,
                      PsMagprs21.2.0$gcv, PsMagprs21.2.1$gcv,
PsMagprs21.2.2$gcv, PsMagprs21.2.3$gcv,
                      PsMagprs21.3.0$gcv, PsMagprs21.3.1$gcv,
PsMagprs21.3.2$gcv, PsMagprs21.3.3$gcv,
                      PsMagprs28.1.0$gcv, PsMagprs28.1.1$gcv,
PsMagprs28.1.2$gcv, PsMagprs28.1.3$gcv,
                      PsMagprs28.2.0$gcv, PsMagprs28.2.1$gcv,
PsMagprs28.2.2$gcv, PsMagprs28.2.3$gcv,
                      PsMagprs28.3.0$gcv, PsMagprs28.3.1$gcv,
PsMagprs28.3.2$gcv, PsMagprs28.3.3$gcv)
#Nilai RS MAGPRS
nilai_rsq_magprs = c(PsMagprs14.1.0$rsq, PsMagprs14.1.1$rsq,
PsMagprs14.1.2$rsq, PsMagprs14.1.3$rsq,
                     PsMagprs14.2.0$rsq, PsMagprs14.2.1$rsq,
PsMagprs14.2.2$rsq, PsMagprs14.2.3$rsq,
                     PsMagprs14.3.0$rsq, PsMagprs14.3.1$rsq,
PsMagprs14.3.2$rsq, PsMagprs14.3.3$rsq,
                     PsMagprs21.1.0$rsq, PsMagprs21.1.1$rsq,
PsMagprs21.1.2$rsq, PsMagprs21.1.3$rsq,
                     PsMagprs21.2.0$rsq, PsMagprs21.2.1$rsq,
PsMagprs21.2.2$rsq, PsMagprs21.2.3$rsq,
                     PsMagprs21.3.0$rsq, PsMagprs21.3.1$rsq,
PsMagprs21.3.2$rsq, PsMagprs21.3.3$rsq,
```

```
                    PsMagprs28.1.0$rsq, PsMagprs28.1.1$rsq,
PsMagprs28.1.2$rsq, PsMagprs28.1.3$rsq,
                    PsMagprs28.2.0$rsq, PsMagprs28.2.1$rsq,
PsMagprs28.2.2$rsq, PsMagprs28.2.3$rsq,
                    PsMagprs28.3.0$rsq, PsMagprs28.3.1$rsq,
PsMagprs28.3.2$rsq, PsMagprs28.3.3$rsq)

data.frame(nilai_nk_magprs, nilai_degree_magprs,
nilai_minspan_magprs, nilai_gcv_magprs, nilai_rsq_magprs)
optimumGCVMagprs=cbind(nilai_nk_magprs, nilai_degree_magprs,
nilai_minspan_magprs, nilai_gcv_magprs)

#mengurutkan nilai GCV MAGPRS minimum
GCVmin1_magprs=optimumGCVMagprs[order(optimumGCVMagprs[,ncol(optimum
GCVMagprs)]),]
GCVmin1_magprs[1,]

#---------------Model Terbaik GCV Minimum dan Rsq Maksimum----------
PsMagprs28.2.2 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=28,
minspan=2,endspan=2, degree=2, penalty=-1,glm=list(family=poisson),
weights = weighted, wp = NULL) #model optimum
bx_magprs = model.matrix(PsMagprs28.2.2)
Ypred_magprs=predict(PsMagprs28.2.2)
lm.mod_magprs <- lm(Ypred_magprs ~ bx_magprs[,-1]) # -1 to drop
intercept
summary(lm.mod_magprs)
summary(PsMagprs28.2.2)

cat(format(lm.mod_magprs, style="bf"))
cat(format(PsMagprs28.2.2, style="bf"))

#Estimasi Variable Penting
PsMagprs28.2.2 = earth(Y~X1+X2+X3+X4+X5+X6+X7, data = data, nk=28,
minspan=2,endspan=2, degree=2, penalty=-1,glm=list(family=poisson),
weights = weighted, wp = NULL) #model optimum
evimp(PsMagprs28.2.2, trim = FALSE)

#Uji Serentak
A=as.matrix(lm.mod_magprs$coefficients)
T=bx_magprs%*%A
Y=as.matrix(data[,3])
teta= 4.241606
R=(Y*(bx_magprs%*%A))-(Y*log(1+teta*exp(bx_magprs%*%A)))+((Y-
1)*log(1+teta*Y))-(log(factorial(Y)))-
(((exp(bx_magprs%*%A))*(1+teta*Y))/(1+teta*exp(bx_magprs%*%A)))
R
ln_Omega=sum(R)
ln_Omega

#Estimasi Menggunakan BHHH
omegakecilawal=c(4.241606) #input nilai awal paramter dispersi
```

```
eps=100
iterasi=1
alpha0=0.021058
N=38
while(eps>00.1){
  omegakecilawal[1]
  a=rep(NA, N)
  b=rep(NA, N)
  for (i in 1:N)
  {
    a[i]=(Y[i]*alpha0)-
((Y[i]*teta*exp(alpha0))/(1+teta*exp(alpha0)))-
(1+teta*Y[i])*((exp(alpha0))/(1+teta*exp(alpha0)))-
((teta*(exp(alpha0))^2)/(1+teta*exp(alpha0))^2)
    b[i]=((Y[i]*exp(alpha0))/(1+teta*exp(alpha0)))+((Y[i]*(Y[i]-
1))/(1+teta*Y[i]))-(exp(alpha0))*(Y[i]/(1+teta*exp(alpha0)))-
(((1+teta*Y[i])*exp(alpha0))/((1+teta*exp(alpha0))^2))
  }
  aa=sum(a)
  bb=sum(b)
  g1=as.matrix(cbind(a,b))
  g=cbind(aa,bb)
  H=(((t(g1)%*%(g1))))
  library(MASS)
  Hinv=ginv(H)
  omegakecilakhir=omegakecilawal+(Hinv%*%(t(g)))
  teta=omegakecilakhir[1]
  omegakecilakhir=c(teta)
  error=abs(omegakecilakhir-omegakecilawal)
  eps=sqrt(sum(error^2))
  omegakecilawal=c(teta)
  iterasi=iterasi+1
}
omegakecilakhir=omegakecilawal
teta=omegakecilawal[1]
diag(Hinv)
SE=sqrt(diag(Hinv))
z_value=omegakecilawal/SE
alpha0
teta
para=(teta)
{
  cat("======================================","\n")
  cat("Estimasi Omega Kecil","\n")
  cat("======================================","\n")
  cat(" estimate std.error z_value","\n")
  cat("teta ",para[1]," ",SE[1]," ",z_value[1],"\n")
  cat("======================================","\n")
}

#---------------------------------------------------------------------
```

```
alpha0=0.021058
teta=4.241606
D=(Y*log(alpha0))-(Y*log(1+teta*exp(alpha0)))+((Y-1)*log(1+teta*Y))-
(log(factorial(Y)))-
(((exp(alpha0))*(1+teta*Y))/(1+teta*exp(alpha0)))
lnomegakecil=sum(D)
Gkuadrat=(2*(ln_Omega)-(lnomegakecil))
ChisqTabel=qchisq(0.95,23)
{
cat("=========================================================","\n")
  cat(" Uji Serentak MAGPRS","\n")

cat("=========================================================","\n")
  cat("G kuadrat Daerah_Kritis Kesimpulan","\n")
  cat( Gkuadrat," ", ChisqTabel," ",if(Gkuadrat> ChisqTabel){
("Tolak H0 dengan alfa 5%")
  } else{("Gagal Tolak H0 dengan alfa 5%")
  },"\n")

cat("=========================================================","\n")
}
```

(Halaman ini sengaja dikosongkan)

Lampiran 10. Surat Pernyatan Data Sekunder

SURAT PERNYATAAN

Saya yang bertanda tangan di bawah ini, mahasiswa Departemen Statistika FSAD ITS:

Nama : Euodia Putri Prastika

NRP : 062116 4000 0026

menyatakan bahwa data yang digunakan dalam Tugas Akhir ini merupakan data sekunder yang diambil dari publikasi lainnya yaitu:

Sumber : Profil Kesehatan Provinsi Jawa Timur Tahun 2018

Keterangan : Data jumlah kematian ibu, persentase kunjungan ibu hamil K1, persentse kunjungan ibu hamil K4, persentase ibu nifas mendapat vitamin A, persentase persalinan ditolong tenaga kesehatan, persentase tablet Fe3 pad ibu hamil, persentase penanganan komplikasi kebidanan, dan persentase peserta KB aktif Provinsi Jawa Timur pada Tahun 2018

Surat Pernyataan ini dibuat dengan sebenarnya. Apabila terdapat pemalsuan data maka saya siap menerima sanksi sesuai aturan yang berlaku.

Mengetahui
Pembimbing Tugas Akhir

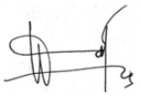

Dr. Bambang Widjanarko O., M.Si
NIP. 19681124 199412 1 001

Surabaya, 29 Mei 2020

Euodia Putri Prastika
NRP. 062116 4000 0026

(Halaman ini sengaja dikosongkan)

BIODATA PENULIS

Penulis dengan nama lengkap Euodia Putri Prastika dilahirkan di Kediri pada tanggal 7 September 1997. Anak dari dari pasangan Bapak Daru Prasongko dan Ibu Titi Karti Andayani. Penulis menempuh pendidikan formal di SD Kristen Petra Madiun, SMPN 1 Madiun, dan SMAN 2 Madiun. Setelah lulus SMA penulis diterima sebagai Mahasiswa Departemen Statistika ITS melalui jalur SNMPTN pada tahun 2016. Selama perkuliahan penulis aktif mengikuti kegiatan di KM ITS. Anak pertama dari dua bersaudara ini pernah bergabung dalam organisasi kemahasiswaan seperti *Staff* Departemen Sosial Masyarakat HIMASTA-ITS 2017/2018 dan Ketua Departemen Sosial Masyarakat HIMASTA-ITS 2018/2019. Selain itu penulis pernah mengikuti beberapa *job survey* dan magang di PDPM ITS sebagai pengaplikasian ilmu statistika. Pada bulan Juli-Agustus 2019 penulis berkesempatan untuk melakukan *internship program* di Dinas Sosial Kota Surabaya bidang Perencanaan, Pendataan, Pengawasan dan Pengendalian Masalah Sosial. Apabila pembaca ingin memberi kritik dan saran serta ingin berdiskusi lebih lanjut mengenai Tugas Akhir ini, dapat menghubungi penulis melalui email euodia.putri97@gmail.com.

(Halaman ini sengaja dikosongkan)