



TUGAS AKHIR - SF 141501

**INVERSI ANOMALI DATA *SELF-POTENTIAL*
MENGUNAKAN ALGORITMA *MICRO-DIFFERENTIAL*
*EVOLUTION***

**ADHISTYA RATNASARI
NRP 0111134000070**

**Dosen Pembimbing
Dr. Sungkono, M.Si.**

**Departemen Fisika
Fakultas Ilmu Alam
Institut Teknologi Sepuluh Nopember
Surabaya 2017**



FINAL PROJECT - SF 141501

**INVERSION OF SELF-POTENTIAL DATA ANOMALIES
USING MICRO-DIFFERENTIAL EVOLUTION
ALGORITHM**

**ADHISTYA RATNASARI
NRP 0111134000070**

Advisor
Dr. Sungkono, M.Si.

Department of Physics
Faculty of Natural Sciences
Institut Teknologi Sepuluh Nopember
Surabaya 2017

LEMBAR PENGESAHAN

**Inversi Anomali Data *Self-Potential* Menggunakan Algoritma
*Micro-Differential Evolution***

TUGAS AKHIR

Disusun untuk memenuhi syarat kelulusan mata kuliah Tugas
Akhir Program S-1

Departemen Fisika, Fakultas Ilmu Alam
Institut Teknologi Sepuluh Nopember

Oleh:

ADHISTYA RATNASARI
NRP 01111340000070

Disetujui Dosen Pembimbing Tugas Akhir

Dr. Sungkono, M.Si
NIP.19850702 201404.1.002

()



**INVERSI ANOMALI DATA *SELF-POTENTIAL*
MENGUNAKAN ALGORITMA *MICRO-DIFFERENTIAL
EVOLUTION***

Nama : Adhistya Ratnasari
NRP : 01111340000070
Jurusan : Fisika, FIA-ITS
Pembimbing : Dr. Sungkono, M.Si

Abstrak

Interpretasi data *self-potential* (*SP*) dapat dilakukan melalui inversi yakni proses pencocokkan data pengukuran dengan data model yang dilakukan secara otomatis. Dengan demikian, diperlukan suatu metode untuk proses tersebut. Penelitian ini, dilakukan untuk mengetahui kemampuan algoritma *Micro-Differential Evolution* (*MDE*) dalam mengestimasi parameter model beserta ketidakpastiannya dari anomali *SP*. Algoritma ini telah di uji pada data sintetik dan data lapangan). Hasilnya ialah pada data sintetik, *MDE* akurat untuk proses inversi data *SP* dan mampu menyediakan *PDM* dengan cepat, sedangkan untuk data lapangan hasil inversinya sesuai dengan metode yang lainnya (*Continuous Wavelet Transform* dan *Flower Polination Algorithm*).

Kata kunci: *MDE, Posterior Distribusi Model (PDM), Self-Potential (SP)*

INVERSION OF SELF-POTENTIAL DATA ANOMALIES USING MICRO-DIFFERENTIAL EVOLUTION ALGORITHM

Name : Adhistya Ratnasari
NRP : 01111340000070
Major : Physics, FIA-ITS
Advisor : Dr. Sungkono, M.Si

Abstract

Interpretation of self-potential (SP) data can be done by inversion through automatically matching measurement data and model data. Thus, it requires a method to complete that process. The objective of this research is to identify Micro-Differential Evolution algorithm ability in estimating parameter model and its uncertainty of SP anomaly. This algorithm has been tested to synthetic and field data. The result is in synthetic data, MDE is accurate for SP data inversion process and able to provide PDM quickly, while for field inversion data results match to another methods such as Continuous Wavelet Transform and Flower Polination Algorithm.

Keywords: MDE, Posterior Distribution Model (PDM), Self-Potential (SP)

KATA PENGANTAR

Puji syukur kehadirat Ilahi Robby yang telah melimpahkan nikmat, hidayah serta inayahNya kepada penulis. sehingga penulis dapat menyelesaikan tugas akhir. Serta tak lupa sholawat dan salam penulis haturkan kepada beliau baginda Rasullah yang telah membawa kita dari zaman kegelapan menuju zaman yang terang benderang. Tugas Akhir (TA) ini penulis susun sebagai syarat wajib untuk memperoleh gelar sarjana di departemen Fisika FIA ITS dengan judul :

INVERSI ANOMALI DATA *SELF-POTENTIAL* MENGUNAKAN ALGORITMA *MICRO-DIFFERENTIAL* *EVOLUTION*

Karya tulis ini, dipersembahkan penulis kepada masyarakat Indonesia pada umumnya dan Kabupaten Ponorogo khususnya. Ucapan terimakasih juga disampaikan penulis kepada segala pihak yang telah mendukung dalam penyelesaian penelitian serta penulisan tugas akhir ini.

1. Bapak Dr. Sungkono, M.Si selaku dosen pembimbing Tugas Akhir yang senantiasa bersabar memberikan bimbingan, arahan, wawasan dan motivasi kepada penulis hingga dapat menyelesaikan tugas akhir.
2. Bapak Dr.rer.nat Bagus Jaya Santosa dan Bapak Diky Anggoro, M.Si selaku dosen penguji Tugas Akhir yang telah memberikan saran-saran serta nasehat kepada penulis.
3. Bapak Heru Sukanto, M.Si selaku dosen wali, yang selalu sabar memberikan nasehat dan arahan kepada penulis.
4. Bapak Dr. Yono Hadi Pramono M. Eng. beserta Bapak Eko Minarto selaku ketua dan sekretaris Jurusan Fisika FMIPA ITS yang telah memberikan kemudahan sarana selama proses kuliah sampai terselesainya Tugas Akhir ini.

5. Seluruh Dosen dan pegawai di jurusan Fisika ITS Surabaya yang telah memberikan ilmu memotivasi dan berbagi pengalaman kepada penulis.
6. Kedua orang tua tercinta, Ibunda Suhartati dan Ayahanda Hadi Mulyono yang selalu memberikan do'a terbaik, kasih sayang terbaik, motivasi terkuat, dan segala yang dibutuhkan penulis.
7. Adik-adikku tercinta Adjimas Fajri N., Aldi Rizki K., Arifia Tirtana yang selalu memberikan dukungan dan tempat berbagi keluh kesah penulis.
8. Teman satu seperjuangan Tugas Akhir Geofisika, Noviantika Fahrina, Aulia 'Urohman, Nurul Huda, M. Husein Al-Faritsi, Badri Gigih S., Dani Urippan, Ahmad Farhan F., M. Kipli, dan Silvia Lestari terimakasih atas semangat dan perjuangan yang telah kita lewati dalam menyelesaikan Tugas Akhir ini.
9. Sahabat-sahabat terbaik Noviantika Fahrina, Wafa Faziatus, Nuri Wachidah, Afidah Zuroidah, Eka Yuliana, Befie Kurnia yang selalu memberikan semangat dalam bentuk apapun, membantu, menemani, tempat curhat, dan menjadi gudang motivasi kepada penulis.
10. Segenap teman-teman Fisika Supernova 2013 yang telah memberikan dukungan terbaik untuk penulis. Terima kasih Supernova 2013 atas pelajaran berharga yang membuat kami menjadi sebuah keluarga.
11. Kawan-kawan satu Lab Geofisika ITS yang telah banyak memberikan sharing ilmunya.

Penulis menyadari dalam penyusunan laporan ini masih terdapat kesalahan. Mohon kritik dan saran pembaca guna menyempurnakan laporan ini. Akhir kata semoga laporan Tugas Akhir ini bermanfaat bagi semua pihak.

Surabaya, Desember 2017

Penulis
adhisty70@gmail.com

DAFTAR ISI

HALAMAN JUDUL	i
COVER PAGE	ii
LEMBAR PENGESAHAN	iii
ABSTRAK	iv
ABSTRACT	v
DAFTAR ISI	xiii
DAFTAR GAMBAR	xv
DAFTAR TABEL	xvii
DAFTAR LAMPIRAN	xix
BAB I	1
PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	2
1.3 Batasan Masalah	2
1.4 Tujuan Penelitian	2
1.5 Manfaat penelitian	2
1.6 Sistematika penulisan	3
BAB II	5
TINJAUAN PUSTAKA	5
2.1 <i>Self-Potential</i> (SP)	5
2.2 Tipe-tipe <i>Self-Potential</i>	7
a) Potensial Elektrokinetik	7
b) Potensial Difusi	8
2.3 Anomali <i>Self-Potential</i>	11
2.4 Pemodelan Ke Depan (<i>Forward Modelling</i>)	12
2.5 Inversi Data SP Menggunakan <i>Differential Evolution</i> (DE)	13
2.5.1 <i>Differential Evolution</i> (DE)	15
2.5.2 <i>Micro-DE</i>	17
BAB III	19
METODOLOGI	19
3.1 Peralatan dan Bahan Penelitian	19
3.2 Prosedur Kerja	19
3.2.1 Studi Literatur	19

3.2.2 Pembuatan Algoritma	19
3.2.3 Input Data	20
3.2.4 Proses Inversi	20
3.2.5 Uji Coba Algoritma MDE.....	20
3.2.6 Analisa hasil dan Kesimpulan.....	20
BAB IV.....	23
ANALISA DATA DAN PEMBAHASAN	23
4.1 Inversi Data Sintetik	23
4.1.1 Efek Populasi	23
4.1.2 Efek Noise	35
4.2 Data Lapangan	44
<i>“Halaman ini sengaja dikosongkan”</i>	<i>48</i>
BAB V	49
KESIMPULAN DAN SARAN	49
5.1 Kesimpulan	49
5.2 Saran	49
DAFTAR PUSTAKA.....	51
LAMPIRAN	53
BIODATA PENULIS.....	61

DAFTAR GAMBAR

Gambar 2.1 Potensial Mineralisasi	10
Gambar 2.2 Model geometri <i>Inclined sheet</i> (El-Kaliouby, 2009)	13
Gambar 3.1 Diagram alir penelitian	21
Gambar 4.2 Misfit sebagai fungsi iterasi pada inversi model data sintetik dengan jumlah populasi 15	25
Gambar 4.3 Posterior distribusi model untuk model sintetik data dengan jumlah populasi 15	26
Gambar 4.5 Misfit sebagai fungsi iterasi pada inversi model data sintetik dengan jumlah populasi 20	28
Gambar 4.6 Posterior distribusi model untuk model sintetik data dengan jumlah populasi 20	29
Gambar 4.7 Hasil pencocokan kurva data sintetis pada uji populasi dengan variasi 25 jumlah populasi	30
Gambar 4.8 Misfit sebagai fungsi iterasi pada inversi model data sintetik dengan jumlah populasi 25	31
Gambar 4.9 Posterior distribusi model untuk model sintetik data dengan jumlah populasi 25	32
Gambar 4.10 Hasil pencocokan kurva data sintetis pada uji populasi dengan variasi 30 jumlah populasi	33
Gambar 4.11 Misfit sebagai fungsi iterasi pada inversi model data sintetik dengan jumlah populasi 30	34
Gambar 4.12 Posterior distribusi model untuk model sintetik data dengan jumlah populasi 30	35
Gambar 4.13 Hasil pemodelan kedepan dari data sintetik tanpa noise	36

Gambar 4.17 Hasil pencocokan kurva data sintetik dengan noise	41
Gambar 4.18 Misfit sebagai fungsi iterasi pada inversi model sintetik dengan noise	42
Gambar 4.19 Posterior distribusi model untuk model sintetik data dengan noise (Titik merah menunjukkan nilai sebenarnya, tanda silang (x) menunjukkan median dari PDM).....	43
Gambar 4.20 Hasil pencocokan kurva SP khayangan api Bojonegoro	45
Gambar 4.21 Misfit sebagai fungsi iterasi data lapangan khayangan api Bojonegoro	46
Gambar 4.22 Posterior distribusi model untuk data lapangan khayangan Bojonegoro.....	47

DAFTAR TABEL

Tabel 2. 1 Sumber dan Nilai Anomali SP (Reynold, 2011).....	6
Tabel 4.1 Hasil inversi data.....	36
Tabel 4.2 Hasil inversi data sintetik ditambah noise.....	44
Tabel 4.3 Hasil Inversi Data Lapangan Kayangan Api Bojonegoro	47

“Halaman ini sengaja dikosongkan”

DAFTAR LAMPIRAN

LAMPIRAN A <i>Algoritma Micro-Differential Evolution</i>	53
LAMPIRAN B <i>Algoritma Posterior Distribusi Model</i>	56

“Halaman ini sengaja dikosongkan”

BAB I PENDAHULUAN

1.1 Latar Belakang

Salah satu metode geolistrik yang digunakan untuk menginterpretasi bawah permukaan pada bidang Geofisika adalah metode *Self-Potential (SP)*. Metode *Self-Potential (SP)* bersifat pasif, sebab pengukurannya dilakukan tanpa memberikan penambahan arus listrik melalui permukaan tanah. Dengan demikian, pengukuran potensial diukur secara alami. Perbedaan potensial alami tanah diukur melalui dua titik di permukaan tanah. Anomali beda potensial ini dapat berupa anomali positif dan negatif.

Dalam analisa data *self-potensial* pada umumnya dapat dilakukan dengan menggunakan dua cara, yaitu : inversi dan analisa sinyal. Analisa data dengan menggunakan proses inversi dilakukan melalui proses pencocokan antara data pengukuran dengan data prediksi (hasil pemodelan kedepan). Hingga saat ini, metode analisa data melalui proses inversi telah banyak dikembangkan, misalnya metode least-square (Abdelrahman and Sharafeldin, 1997), metode Differential Evolution (Ales, 2014), neural networks (NN) (El-Kaliouby, 2009).

Berkaitan dengan inversi yang bertujuan untuk meminimumkan suatu fungsi objektif. Tetapi faktanya fungsi objektif pada proses inversi memiliki banyak minimum lokal. Sehingga, metode-metode biasa yang berkaitan dengan optimum lokal seperti metode Gauss-Newton solusinya akan terjebak pada minimum lokal. Apabila terjebak pada minimum lokal, solusi model tersebut salah. Metode-metode optimum global yang biasa digunakan misalnya algoritma genetik dan Monte-Carlo memerlukan waktu yang cukup lama (*time consuming*) karena memerlukan banyak perhitungan *forward-modelling*. Untuk menyelesaikan kedua masalah tersebut yaitu solusi yang terjebak pada minimum lokal dan *time consuming* tersebut, maka dalam penelitian ini akan digunakan algoritma *Micro-Differential Evolution*.

Micro-Differential Evolution merupakan teknik komputasi evolusioner yang terdiri dari beberapa proses, yaitu inialisasi, mutase, *crossover*, dan seleksi (Ren et al, 2010). Dalam penelitian ini, digunakan algoritma *Micro-Differential Evolution* untuk menguji kemampuan serta tingkat optimasi algoritma tersebut pada proses inversi data SP.

1.2 Rumusan Masalah

Berdasarkan latar belakang di atas, permasalahan yang dirumuskan dalam penelitian ini antara lain:

1. Bagaimana kemampuan algoritma *Micro-Differential Evolution* dalam proses inversi anomali SP?
2. Bagaimana tingkat optimasi algoritma *Micro-Differential Evolution* dalam proses inversi anomali SP?

1.3 Batasan Masalah

Terdapat beberapa batasan masalah pada penelitian ni, antara lain:

1. Proses inversi data self-potensial menggunakan algoritma *Micro-Differential Evolution*
2. Data yang digunakan merupakan data *Self-Potential*.
3. *Software* yang digunakan ialah MATLAB R2013a.

1.4 Tujuan Penelitian

Berdasarkan rumusan masalah diatas, maka tujuan dari penelitian ini antara lain:

1. Mengetahui kemampuan algoritma *Micro-Differential Evolution* dalam proses inversi anomali data SP.
2. Mengetahui tingkat optimasi algoritma *Micro-Differential Evolution* dalam proses anomali data SP.

1.5 Manfaat penelitian

Manfaat penelitian ini yaitu dapat mengetahui kemampuan algoritma *Micro-Differential Evolution* dalam proses inversi anomali data SP. Selain itu juga dapat mengetahui tingkat

optimasi algoritma tersebut dalam proses inversi anomali data SP. Sehingga hasil penelitian ini diharapkan dapat memberikan pemahaman mengenai penggunaan algoritma *Micro-Differential Evolution* untuk proses inversi anomali data SP.

1.6 Sistematika penulisan

Sistematika penulisan pada laporan tugas akhir ini adalah sebagai berikut:

1. BAB I – Pendahuluan, berisi tentang latar belakang masalah, rumusan masalah, tujuan penelitian, batasan masalah, manfaat penelitian dan sistematika penelitian tugas akhir.
2. BAB II – Tinjauan Pustaka, berisi uraian teori yang mendukung penelitian tugas akhir.
3. BAB III – Metodologi Penelitian, berisi tentang uraian alat dan bahan, data penelitian, *software* yang digunakan serta metode dan tahapan yang dilakukan selama penelitian.
4. BAB IV – Analisa Data dan Pembahasan, berisi hasil yang diperoleh dari penelitian ini.
5. BAB V – Kesimpulan, berisi kesimpulan dari hasil analisa pada penelitian yang telah dilakukan serta saran-saran untuk mendukung penelitian selanjutnya.
6. Lampiran, berisi data-data yang digunakan dalam penelitian beserta beberapa gambar yang menunjang penelitian.

“Halaman ini sengaja dikosongkan”

BAB II

TINJAUAN PUSTAKA

2.1 *Self-Potential* (SP)

Self Potential merupakan salah satu metode pengukuran geofisika yang termasuk dalam metode survei geolistrik, metode ini banyak digunakan untuk mengetahui aliran fluida bawah permukaan. Metode ini termasuk dalam metode geofisika pasif dikarenakan metode ini tidak memberikan gangguan terhadap bumi. Metode *Self Potential* ini berprinsip menerima dan mengukur tegangan statis alam yang berada di titik permukaan bumi. *Self Potential* yang terukur pada permukaan bumi dapat bernilai kurang dari satu milivolt (mV) sampai satu volt dengan tanda positif dan negatif. Variasi nilai *Self Potential* ini dipengaruhi oleh reaksi kimia yang terjadi dalam bumi dan air tanah dalam bumi. Tabel 2.1 merupakan nilai anomali SP dan sumber geologi yang menghasilkan anomali tersebut. Potensial alami dapat terjadi akibat adanya perbedaan material, konsentrasi larutan elektrolit, pengaruh temperatur, dan adanya suatu aliran fluida. Potensial alami di dalam bumi terdiri dari 2 komponen yaitu komponen yang selalu konstan dan tidak memiliki arah serta komponen yang selalu berubah-ubah terhadap waktu (El-Araby, 2004).

Reaksi kimia dalam bumi sangat mempengaruhi nilai potensial alam, reaksi kimia tersebut meliputi aktivitas elektrokimia dan mekanis. Nilai potensial alam juga berhubungan dengan air tanah, karena air tanahlah yang menjadi faktor pengontrol dari reaksi kimia yang terjadi dalam bumi (Telford et al., 1990). Air tanah berperan dalam aktivitas biolistrik yang terjadi pada tanaman serta bahan organik, proses korosi, variasi sifat batuan, pelapukan tubuh mineral, tekanan dalam bumi, gradien termal dan sebagainya. Tabel 2.1 di bawah ini merupakan nilai anomali SP dan juga sumber geologi yang menghasilkan anomaly tersebut. Sebagai tambahan, geometri dari struktur geologi juga dapat menghasilkan anomali dari *Self-Potential*.

Tabel 2. 1 Sumber dan Nilai Anomali SP (Reynold, 2011)

Sumber	Nilai Anomali
Potensial background	
- Reaksi Geokimia dan streaming fluida	Positif atau negatif kurang dari sama dengan 100 mV
- Pergerakan air tanah	Negatif kurang dari sam dengan 300 mV
- Topografi	Negatif lebih dari 2V
Potensial Mineral	
- Sulfida (pyrite, chalcopyhte, pyrhotite, sphalerite, galena)	Negatif mencapai ratusan mV
- Graphite (magnetite dan bahan konduksi elektronik)	
- Coal	
- Mangan	
- Kuarsa	Positif mencapai ratusan mV

Reaksi serta proses kimia akan menghasilkan beberapa nilai potensial diantaranya: potensial *liquid-junction*, potensial *shale (nernst)*, serta potensial mineralisasi (Telford et al., 1990). Nilai potensial alam pada bumi tersusun atas dua komponen, yaitu komponen yang konstan dan komponen yang berubah ubah terhadap waktu. Komponen konstan dipengaruhi oleh proses elektrokimia dalam bumi sedangkan komponen yang berubah ubah disebabkan karena adanya perbedaan potensial dari arus bolak balik yang terinduksi oleh petir (alami) dan perbedaan medan magnet bumi. Perbedaan medan magnet bumi dipengaruhi

oleh curah hujan. Dari hasil penelitian Reynold (1997) dinyatakan bahwa *Self Potential* berhubungan dengan debit aliran fluida serta kandungan elektrolit. Debit aliran fluida yang lebih besar akan menghasilkan nilai potensial diri yang lebih besar, dan kandungan elektrolit yang lebih besar juga akan menghasilkan nilai potensial diri yang lebih besar. Namun secara umum faktor utama yang mempengaruhi nilai potensial diri adalah air yang terkandung dalam tanah.

Menurut Reynold (1997) menyatakan bahwa terdapat tiga cara dalam mengkonduksi listrik melalui batuan diantaranya melalui dielektrik, elektrolit, dan konduksi elektrolit. Untuk konduktivitas listrik pada batuan nilainya bergantung terhadap porositasnya dan pergerakan air atau cairan lainnya yang melewati celah pori (sifat mobilitas ionik, konsentrasi larutan, viskositas, temperatur dan tekanan).

2.2 Tipe-tipe *Self-Potential*

Ada beberapa tipe dari *self-potential* (*SP*) berdasarkan penyebabnya antara lain :

a) Potensial Elektrokinetik

Potensial elektrokinetik atau biasa disebut *elektromechanical potential* merupakan potensial yang terbentuk karena adanya pergerakan elektrolit atau aliran fluida air tanah yang melalui celah pori atau kapiler.. Potensial elektrokinetik bawah permukaan tanah dapat disebabkan oleh aliran fluida yang melewati suatu medium, sehingga terjadilah pertukaran ion antara fluida dengan partikel dalam tanah tersebut. Nilai potensial yang dihasilkan dari proses ini digolongkan sebagai *electrofiltration* atau *streaming potential*. Potensial diukur sepanjang kapiler tersebut. Besarnya resultan beda potensial antara ujung gaya dirumuskan dalam persamaan berikut:

$$V_k = - \frac{\varphi \Delta P \cdot \varepsilon \cdot \rho}{4 \pi \eta}$$

(2.1)

Dengan ϕ , ϵ , η , ρ masing masing adalah potensial absorpsi (volt), konstanta dielektrik larutan, viskositas larutan, dan resistivitas listrik. Serta ΔP adalah beda tekanan (N/m^2).

b) Potensial Difusi

Potensial elektrokimia timbul karena proses kimia dimana meliputi potensial difusi dan potensial nerst. Saat konsentrasi elektrolit dalam tanah bervariasi, maka perbedaan potensial akan muncul sebagai akibat perbedaan mobilitas anion dan kation dalam larutan yang konsentrasinya berbeda. Potensial ini yang disebut dengan potensial difusi (*liquid junction* atau *diffusion potential*). Besarnya potensial difusi ini dirumuskan dalam bentuk persamaan berikut :

$$V_d = - \frac{R \theta (I_a - I_c)}{F n (I_a + I_c)} \log \frac{C_1}{C_2} \quad (2.2)$$

Dengan R , F , n , masing masing adalah konstanta gas (8,31 Joule/ $^{\circ}C$), F konstanta Faraday ($9,65 \times 10^4$ Cal/mol) dan n merupakan valensi. Sedangkan I_a , I_c merupakan mobilitas anion dan kation. C_1 dan C_2 konsentrasi larutan (mol/m^3). Serta θ yaitu temperatur absolut (K).

c) Potensial Nernst

Potensial *Nernst* merupakan nilai beda potensial akibat adanya perbedaan potensial antara dua logam identik yang dicelupkan dalam larutan homogen tetapi konsentrasi larutan setiap elektroda berbeda. Dimana besar nilai potensial berbanding lurus dengan temperatur dan konsentrasi. Hal ini menunjukkan bahwa metode SP baik digunakan dalam eksplorasi geotermal. Persamaan untuk mendapatkan potensial *Nernst* sama dengan persamaan potensial difusi namun dengan syarat $I_a = I_c$. Potensial Nernst (*shale*) terjadi ketika perbedaan potensial diantara kedua elektroda yang dicelupkan pada larutan homogen yang mempunyai konsentrasinya berbeda-beda. Besarnya potensial nerst dapat dituliskan sebagai berikut :

$$V_S = - \frac{R \theta}{F n} \log \frac{C_1}{C_2} \quad (2.3)$$

Besarnya potensial elektrokimia merupakan perpaduan antara potensial nerst dan potensial difusi. Persamaan 2.3 menunjukkan bahwa potensial elektrokimia bergantung pada temperatur dan konsentrasi. Nilai potensial akan besar apabila temperatur dan konsentrasinya tinggi, karena hal inilah pengukuran potensial diri sangat penting dalam eksplorasi sumber sumber geothermal yang mana nilai temperatur memang benar memiliki elevasi dan konsentrasi garam di dalam air tanah sangat tinggi.

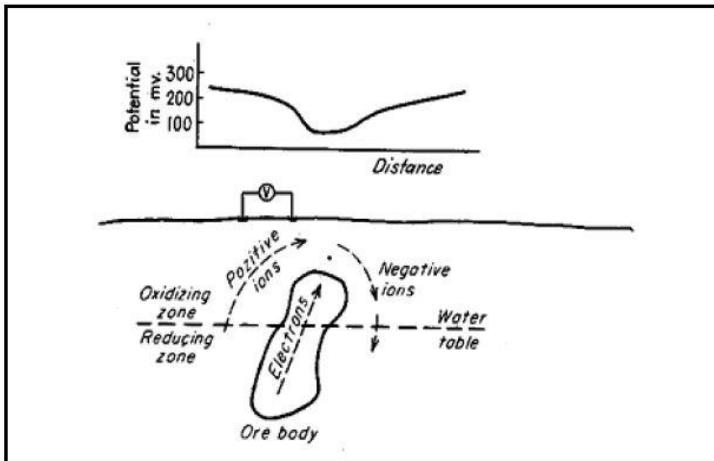
d) Potensial Mineralisasi

Apabila 2 macam logam dimasukkan dalam suatu larutan homogen, maka pada logam tersebut akan timbul beda potensial. Beda potensial ini yang disebut dengan potensial kontak elektrolit (Dehbashi and Asl, 2014). Potensial kontak elektrolit dan potensial elektrokimia sering timbul dan dapat diukur dipermukaan dimana pada daerah yang banyak mengandung mineral. Sehingga dalam hal ini kedua proses timbulnya potensial disebut sebagai potensial mineralisasi. Potensial mineralisasi bernilai kurang dari 100 mV. Elektron ditransfer melalui tubuh mineral dari pereduksi di bawah muka air tanah menuju pengoksidasi di atas muka air tanah.

Proses potensial mineralisasi dapat dilihat pada Gambar 2.1. Berdasarkan gambar tersebut dilihat bahwa pada bagian atas tubuh sulfida terjadi proses reduksi sedangkan proses oksidasi terjadi pada bagian bawah sehingga terbentuklah cell. Dan pada bagian dalam tubuh mineral berfungsi sebagai jalur transport dari anoda ke katoda. Salah satu yang mempengaruhi dalam eksplorasi mineral yaitu potensial mineral itu sendiri. Anomali negatif yang besar dapat diamati pada *pyrite*, *chalcopyte* serta beberapa konduktor listrik yang baik. Meskipun sebagian besar anomali pada mineral potensial mempunyai sifat konduktor yang baik, akan tetapi ada juga yang mempunyai sifat konduktor yang kurang baik seperti pada *sphalerite*.

Untuk menghindari kesalahan pengukuran potensial karena adanya potensial polarisasi yang timbul pada permukaan

elektroda logam, maka pengukuran SP menggunakan elektroda khusus yang disebut *non polarisable electrode*. Elektroda ini terbuat dari logam yang dicelupkan dalam wadah yang berporos, elektroda ini disebut dengan *porous pot electrode*.



Gambar 2.1 Potensial Mineralisasi

Pada penjelasan Sato dan Mooney (1960), mereka menjelaskan bahwa dua reaksi elektrokimia *half-cell* dari tanda yang berkebalikan, satu katoda diatas *water table*, yang lainnya anoda dibawahnya. Sedangkan pada bagian katoda setengah *cell* terjadi reaksi reduksi kimia yang mendapatkan elektron dan pada sel anoda terjadi reaksi oksidasi yaitu menghilangnya elektron. Zona mineral berfungsi hanya untuk menghubungkan elektron dari anoda dan katoda. Perbedaan potensial oksidasi diantara solusi-solusi pada dua *half-cell* yang menentukan efek potensial diri secara keseluruhan.

e) Potensial Termoelektrik

Saat gradien temperatur melewati suatu sampel batuan maka akan menghasilkan medan listrik saat melewati batuan tersebut. Fenomena ini disebut dengan efek termoelektrik yang

kemungkinan disebabkan oleh adanya perbedaan difusi termal dari ion-ion pada pori fluida serta dari elektron-elektron dan donor ion pada batuan, proses tersebut dinamakan efek Seebeck. Rasio tegangan terhadap perbedaan suhu, disebut koefisien kopling termoelektrik (Sharma, 1997).

Daerah yang terkonsentrasi pada suhu tinggi pada kedalaman dangkal, seperti cairan termal di zona sesar, dapat menyebabkan anomali dengan panjang gelombang lebih pendek dan amplitudo yang lebih besar. Batas-batas anomali SP yang diukur di beberapa daerah panas bumi tampak berkorelasi dengan zona anomalipanas tinggi yang diketahui. Hal ini kemungkinan anomali ini dihasilkan oleh mekanisme termoelektrik.

2.3 Anomali *Self-Potential*

Pada data *Self-Potential* akan sangat berpengaruh terhadap faktor pengendali yaitu aliran fluida bawah permukaan. Aliran bawah permukaan akan mudah terganggu dengan perbedaan temperatur, tekanan, atau konsentrasi dari bahan kimia, sehingga nilai potensial yang dihasilkan juga akan sensitif pada faktor-faktor pengganggu tersebut. Pada *Self-Potential*, nilai amplitudo dari anomali akan bergantung terhadap nilai perbedaan tekanan dan koefisien cross-coupling yang berhubungan dengan aliran air bawah permukaan, panas, serta bahan yang dapat menimbulkan potensial serta resistivitas listrik dari struktur bumi (Telford et al., 1990).

Penentuan anomali pada pengukuran Self Potential yang disebabkan oleh mineral yang berada dibawah permukaan, maka dilakukan pendekatan dengan memodelkan mineral sebagai bola seperti yang terdapat pada Gambar 2.1. Kandungan dari mineral yang berada dibawah permukaan diasumsikan sebagai suatu mineral yang merupakan sumber dari anomali *Self Potential* yang berada dibawah permukaan tanah dengan kedalaman h serta mempunyai sudut polarisasi sebesar α . Gambar 2.1 merupakan pemodelan dari anomali Self Potential dapat terlihat jika amplitudo dari data menunjukkan perubahan yang sangat drastis tepat di daerah kandungan mineral. Data pengukuran *Self*

Potential dapat diinterpretasikan secara kualitatif maupun kuantitatif, namun cara menginterpretasikannya yang bergantung dengan tujuan dari penelitian yang akan dicapai.

2.4 Pemodelan Kedepan (*Forward Modelling*)

Pemodelan ke depan atau biasa disebut *forward modelling* merupakan suatu proses perhitungan data yang secara teoritis akan teramati pada permukaan bumi saat parameter model diketahui (Grandis, 2009). Pemodelan kedepan ini diperlukan untuk menganalisis data geofisika melalui proses inversi ataupun sebagai studi awal dalam desain pengukuran. Untuk proses inversi, saat respon suatu model yang cocok atau sesuai dengan data pengukuran, model yang digunakan untuk memperoleh respon tersebut dapat dianggap mewakili kondisi bawah permukaan di lokasi pengukuran (Samudra and Warnana, 2017).

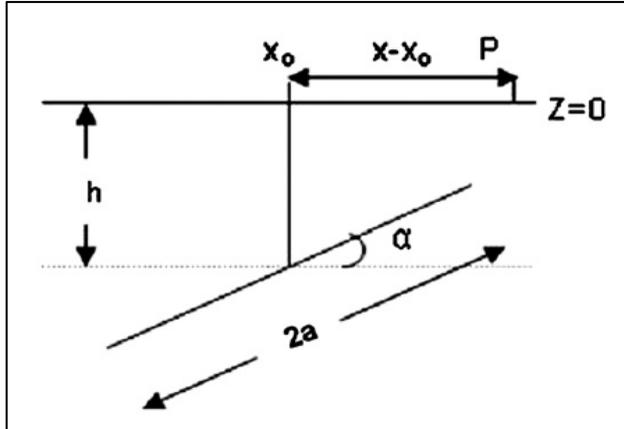
Pemodelan kedepan untuk potensial diri, umumnya terdapat beberapa pendekatan, yakni : pemodelan dengan tubuh anomali ideal (bola, horizontal silinder, dan retakan), dan pemodelan yang lebih kompleks tanpa menggunakan asumsi bentuk anomalnya (biasanya menggunakan metode *Finite element*). Namun, karena dalam penelitian ini difokuskan untuk inversi model dengan asumsi anomali berupa struktur, maka pemodelan kedepan yang dibahas hanya mencakup tentang pemodelan kedepan menggunakan struktur.

El-Kaliboy dan Al-Gami (2009) menggambarkan anomaly self-potential sesuai Gambar 2.2 dan menjelaskan persamaan umum potensi anomali SP pada setiap titik P di permukaan P(x) dengan sumber anomali *inclined sheet* sebagai berikut :

$$V(x_i) = k \ln \left\{ \frac{\left[(x_i - x_0) - a \cos \alpha \right]^2 + (h - a \sin \alpha)^2}{\left[(x_i - x_0) + a \cos \alpha \right]^2 + (h + a \sin \alpha)^2} \right\} \quad (2.4)$$

dengan parameter polarisasi k adalah momen dipol arus listrik di permukaan $\left(k = \frac{I\rho}{2\pi} \right)$, h adalah kedalaman bagian tengah *sheet*,

α merupakan kemiringan, a adalah setengah panjang dari struktur, dan ρ adalah resistivitas medium. Sedangkan x_0 dan I masing-masing adalah jarak nol dari posisi awal dan arus dari medium. Parameter tersebut pada saat perhitungan respon pemodelan ke depan diubah-ubah, kemudian dioptimasi dengan metode inversi sehingga didapatkan model yang cocok dengan data obeservasi.



Gambar 2.2 Model geometri *Inclined sheet* (El-Kaliouby, 2009)

2.5 Inversi Data SP Menggunakan *Differential Evolution (DE)*

Inversi didefinisikan sebagai suatu kesatuan teknik atau metode matematika dan statistika yang bertujuan untuk memperoleh informasi parameter model yang berguna dalam suatu sistem fisika dari data pengukuran (Grandis, 2009). Dalam proses inversi, harus terdapat beberapa proses modifikasi model agar diperoleh kesesuaian yang optimal antara data perhitungan dan pengamatan. Pemodelan tersebut dinamai dengan data *fitting*, karena dalam prosesnya yang dicari adalah parameter model yang menghasilkan respons yang sesuai dengan data pengamatan (Sudiar and Akmam, 2016). Kesesuaian antara respon model dengan data pengamatan secara umum dapat dinyatakan dalam suatu fungsi objektif yang harus diminimumkan. Pencarian fungsi objektif yang minimum ini berasosiasi dengan proses pencarian model optimum (Reynolds, 1998). Di dalam proses inversi,

analisis terhadap data lapangan dengan cara melakukan pencocokan kurva antara model matematika dengan data lapangan.

Dalam masalah inversi, akan selalu berhubungan dengan jumlah parameter model (M) dan jumlah data (N). Jumlah dari masing-masing ini menentukan klasifikasi permasalahan inversi dan cara penyelesaiannya. Apabila jumlah model parameter lebih sedikit dibandingkan data observasi ($M < N$), maka permasalahan inversi ini disebut *overdetermined*. Sedangkan saat jumlah parameter yang ingin dicari (M) lebih banyak daripada jumlah datanya (N), maka masalah inversi ini disebut dengan *underdetermined* (Supriyanto, 2007). Terakhir, ketika jumlah data sama atau hampir sama dengan jumlah parameter, hal ini disebut dengan *evendetermined*.

Dalam proses inversi terdapat suatu fungsi tujuan untuk mencapai model yang terbaik. Pada penelitian ini fungsi objektif (Q) dapat dituliskan dengan persamaan berikut:

$$Q = \frac{2 \sum_i^N |V_i^o - V_i^c|}{\sum_i^N |V_i^o - V_i^c| + \sum_i^N |V_i^o + V_i^c|} \quad (2.5)$$

dengan N merupakan angka yang terbaca, V_i^o dan V_i^c masing-masing menunjukkan anomali SP yang terukur dan perhitungan pada point P(x_i). Ketidaksesuaian antara respon data dan model dievaluasi melalui kesalahan relatif rata-rata, yang dihitung dengan persamaan berikut:

$$misfit(\%) = \frac{100}{N} \sqrt{\sum_i^N \left(\frac{V_i^o - V_i^c}{V_i^o} \right)^2} \quad (2.6)$$

Inversi data SP menggunakan algoritma *Differential Evolution* (DE) telah banyak digunakan sebelumnya. *Differential Evolution*

(DE) merupakan teknik komputasi evolusi (Storn and Price, 1997) yang terdiri dari beberapa proses yaitu : inialisasi, mutasi, *crossover*, dan seleksi.

2.5.1 Differential Evolution (DE)

Differential Evolution (DE) adalah suatu teknik komputasi evolusi yang terdiri dari beberapa proses yaitu inialisasi, mutasi, *crossover*, dan seleksi. Seperti metode optimasi global lainnya, DE diawali dengan pembangkitan populasi dengan N adalah individu dalam ruang pencarian solusi parameter model yang diestimasi. Dengan demikian, populasi dengan individu masing-masing-masing generasi dapat dilambangkan sebagai berikut :

$$P_{i,G} = [X_{i,1}^j, X_{i,2}^j, \dots, X_{i,G_{\max}}^j], \quad G = 1, 2, 3 \dots G_{\max} \quad (2.7)$$

$$X_i^j = [X_i^1, X_i^2, \dots, X_i^D], \quad j = 1, 2, 3 \dots D; \quad i = 1, 2, 3, \dots, N$$

dengan N adalah ukuran populasi, X adalah parameter model yang dicari, G_{\max} adalah generasi maksimum, dan D mendefinisikan jumlah parameter model. Setiap individu disebut sebagai kromosom yang merupakan kandidat solusi dalam masalah optimasi. Populasi awal harus mencakup ruang pencarian yang dilakukan dengan mengacak secara seragam dari ruang pencarian yang dibatasi oleh batasan parameter minimum dan maksimum yang ditentukan, yakni $X_{\min} = [X_{\min}^1, X_{\min}^2, \dots, X_{\min}^D]$

dan $X_{\max} = [X_{\max}^1, X_{\max}^2, \dots, X_{\max}^D]$, dengan X_{\max} dan X_{\min} merupakan batasan solusi. Sebagai contoh, nilai awal setiap parameter j dan setiap individu i, populasi awal dapat dihasilkan oleh:

$$X_i^j = X_{\min}^j + \text{rand}[0,1] \cdot (X_{\max}^j - X_{\min}^j) \quad (2.8)$$

Setelah proses inialisasi awal, setiap kromosom dilakukan proses mutasi. Operator mutase menghasilkan vektor mutan $V_{i,G} = [v_{i,G}^1, v_{i,G}^2, \dots, v_{i,G}^D]$. $V_{i,G}$ dapat dihasilkan dengan menggunakan metode mutase tertentu. Berikut ini, merupakan

pendekatan-pendekatan yang sering digunakan untuk proses mutasi (Epitropakis et al., 2011) :

1) DE/rand/1

$$V_{iG} = X_{r_1^i, G} + F_1 \left(X_{r_2^i, G} - X_{r_3^i, G} \right) \quad (2.9)$$

2) DE/best/1

$$V_{iG} = X_{best, G} + F_1 \left(X_{r_1^i, G} - X_{r_2^i, G} \right) \quad (2.10)$$

3) DE/best/2

$$V_{iG} = X_{best, G} + F \left(X_{r_1^i, G} - X_{r_2^i, G} \right) + F \left(X_{r_3^i, G} - X_{r_4^i, G} \right) \quad (2.11)$$

4) DE/rand/2

$$V_{iG} = X_{r_1^i, G} + F \left(X_{r_2^i, G} - X_{r_3^i, G} \right) + F \left(X_{r_4^i, G} - X_{r_5^i, G} \right) \quad (2.12)$$

5) DE/rand-to-best/1

$$V_{iG} = X_{i, G} + K \left(X_{best, G} - X_{i, G} \right) + F \left(X_{r_1^i, G} - X_{r_2^i, G} \right) \quad (2.13)$$

6) DE/rand-to-best/2

$$V_{iG} = X_{i, G} + K \left(X_{best, G} - X_{i, G} \right) + F \left(X_{r_1^i, G} - X_{r_2^i, G} + X_{r_3^i, G} - X_{r_4^i, G} \right) \quad (2.14)$$

7) DE/current-to-best/1

$$V_{iG} = X_{i, G} + K \left(X_{r_1^i, G} - X_{i, G} \right) + F \left(X_{r_2^i, G} - X_{r_3^i, G} \right) \quad (2.15)$$

Dengan r_1, r_2, r_3, r_4 dan r_5 adalah indeks partikel yang dihasilkan secara acak dalam kisaran $[1, N]$ dengan $r_1 \neq r_2 \neq r_3 \neq r_4 \neq r_5$. Parameter F disebut sebagai faktor skala mutasi dengan memiliki rentang $[0, 2]$. $X_{best, G}$ adalah vektor individu dengan nilai *fitness* terbaik dalam ukuran populasi pada generasi G sedangkan K secara acak berada dalam kisaran $[0, 1]$.

Setelah proses mutasi, *crossover* binomial diterapkan untuk mendapatkan vektor $U_{i,G} = [u_{i,G}^1, u_{i,G}^2 \dots u_{i,G}^D]$ yang dapat dilakukan dengan cara sebagai berikut:

$$u_{i,G}^j = \begin{cases} v_{i,G}^j & \text{jika } (rand(0,1) \leq C_r \text{ atau } (j = j_{rand})) \\ X_{i,G}^j & \text{, selain itu} \end{cases} \quad (2.16)$$

dengan C_r adalah tingkat *crossover* dengan kisaran $[0, 1]$, yang mengendalikan berapa banyak komponen yang bermutasi pada masing-masing elemen dari vektor mutan saat ini. j_{rand} didefinisikan sebagai bilangan bulat yang dipilih secara acak pada kisaran $[1, D]$. Operator *crossover* binomial menyalin parameter ke- j dari vektor mutan $V_{i,G}$ ke elemen yang sesuai dalam vektor percobaan $U_{i,G}$, saat $rand(0,1) \leq C_r$ atau $j = j_{rand}$. Jika tidak, maka akan disalin dari vektor target $X_{i,G}$ yang sesuai.

Selanjutnya, operasi seleksi untuk memilih vektor induk $X_{i,G}^j$ yang lebih baik dan vektor mutasi $u_{i,G}^j$ berdasarkan fungsi *fitness* $f(\cdot)$ mereka. Misalnya, untuk masalah minimisasi (seperti masalah inversi), vektor terpilih yang digunakan sebagai vektor induk pada generasi berikutnya diberikan oleh :

$$X_{i,G+1}^j = \begin{cases} u_{i,G}^j & \text{jika } f(u_{i,G}^j) \leq f(X_{i,G}^j) \\ X_{i,G}^j & \text{, selain itu} \end{cases} \quad (2.17)$$

2.5.2 Micro-DE

Ren et al. (2010) menunjukkan bahwa pendekatan mutasi sebagai uraian di atas (DE) akan prematur saat populasi kecil diterapkan. Untuk mengatasi masalah tersebut, Ren et al. (2010) mengusulkan metode untuk memperbesar keragaman suatu populasi sebagai berikut :

$$V_{i,G} = X_{r_1',G} + F_1 * (X_{r_2',G} - X_{r_3',G} + r * \delta) \quad (2.18)$$

dengan r merupakan nilai acak dalam $[-1,1]$ dan δ mendefinisikan nilai intensitas gangguan. δ diinisialisasi menggunakan $\delta = 0.2(X_{\max} - X_{\min})$. Selanjutnya, untuk penentuan intensitas gangguan diperbarui berdasarkan persamaan berikut :

$$\delta = \begin{cases} \delta\eta & \text{jika } IR < 0.2 \\ \delta / \eta & \text{jika } IR > 0.2 \\ \delta & \text{jika } IR = 0.2 \end{cases} \quad (2.19)$$

dengan IR menunjukkan tingkat perbaikan, sedangkan $\eta = 0.9$ merupakan rasio antara jumlah individu yang membaik berdasarkan ukuran populasi setelah operasi seleksi.

BAB III METODOLOGI

3.1 Peralatan dan Bahan Penelitian

Peralatan dan bahan yang digunakan dalam penelitian tugas akhir ini antara adalah *Personal Computer (PC)* yang telah terinstal software Matlab R2013a, dan data pengukuran *Self-Potential*.

3.2 Prosedur Kerja

Alur pada penelitian ini ditampilkan oleh Gambar 3.1 yang dapat diuraikan sebagai berikut:

3.2.1 Studi Literatur

Studi literatur merupakan tahap awal untuk melakukan sebuah penelitian. Dalam tahap ini perlu memahami tentang konsep dari penelitian yang dilakukan dengan mencari referensi seperti buku, jurnal, tugas akhir ataupun thesis terkait penelitian. Penelitian ini perlu memahami tentang konsep yang berhubungan dengan metode *Self-Potential (SP)*, algoritma *Micro-Differential Revolution* untuk data SP, serta mempelajari proses inversi data SP. Langkah ini dilanjutkan dengan mencari dan mempelajari referensi-referensi terkait dengan penelitian ini. Referensi berupa ebook, jurnal internasional, jurnal nasional, maupun tugas akhir yang berkaitan dengan inversi, pengolahan data, dan interpretasi.

3.2.2 Pembuatan Algoritma

Tahap yang kedua yaitu pembuatan program inversi dengan menggunakan algoritma *Micro-Differential Revolution*. Algoritma ini termasuk dalam solusi optimum global. Keberhasilan algoritma DE atau mikro-DE bergantung pada dua parameter, yaitu faktor skala mutasi (F) dan probabilitas / laju *crossover* (Cr). Untuk performa terbaik DE atau rentang parameter yang direkomendasikan oleh mikro-DE sebagai: probabilitas *crossover* memiliki rentang [0, 1] dan faktor skala memiliki rentang [0.4,1] (Storn dan Price, 1997). Ada beberapa parameter populer untuk F dan Cr dalam literatur untuk proses inversi, seperti: (F,Cr) = (0.86,0.98) (Li et al., 2010), (F,Cr) =

(0.5,0.8) (Fernández-Martínez et al., 2009), $(F,Cr) = (0.7,0.5)$ (Růžek dan Kvasnička, 2005), dan pendekatan adaptif terhadap Tentukan F dan Cr (Brown et al., 2016; Guo et al., 2014). Dalam hal ini, $(F,Cr) = (0.7,0.5)$ digunakan untuk semua proses inversi.

3.2.3 Input Data

Pada proses ini, dilakukan input data dari *self-potensial*. Proses ini bisa dilakukan setelah pembuatan algoritma telah selesai.

3.2.4 Proses Inversi

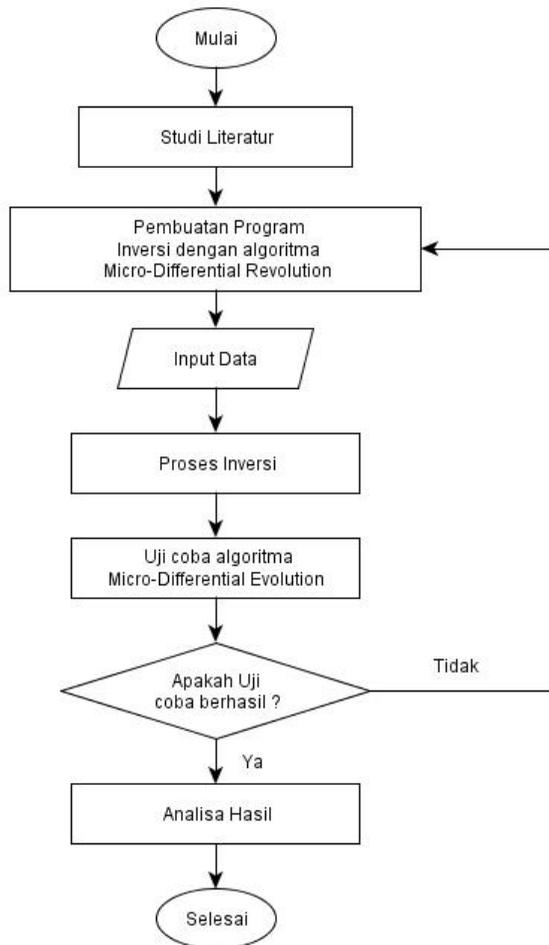
Proses inversi pada penelitian ini menggunakan algoritma *Micro-Differential Revolution*. Tahap ini dilakukan untuk menguji optimasi dari algoritma *Micro-Differential Revolution* dalam proses pengolahan data SP.

3.2.5 Uji Coba Algoritma MDE

Pada tahap ini, dilakukan uji optimasi dengan menganalisa waktu yang diperlukan dalam proses inversi. Proses ini dilakukan dengan bantuan software Matlab R2013a. Dari proses ini akan diketahui pula bagaimana kemampuan algoritma MDR dalam melakukan proses inversi.

3.2.6 Analisa hasil dan Kesimpulan

Pada tahap analisa dan interpretasi ini dilakuka setelah memperoleh hasil pemodelan dari proses inversi. Dari hasil model tersebut dilakukan evaluasi program dengan data dan disesuaikan kembali dengan asumsi awal. Analisa ini dilakukan untuk menjawab dari permasalahan pada penelitian ini. Dari hasil analisa tersebut maka dapat diperoleh suatu kesimpulan yang dapat menjawab tujuan dari penelitian ini.



Gambar 3.1 Diagram alir penelitian

“Halaman ini sengaja dikosongkan”

BAB IV ANALISA DATA DAN PEMBAHASAN

Pada bab ini akan menjelaskan mengenai proses inversi data SP sertatingkat optimasi menggunakan algoritma *Micro-Differential Evolution* (MDE).

4.1 Inversi Data Sintetik

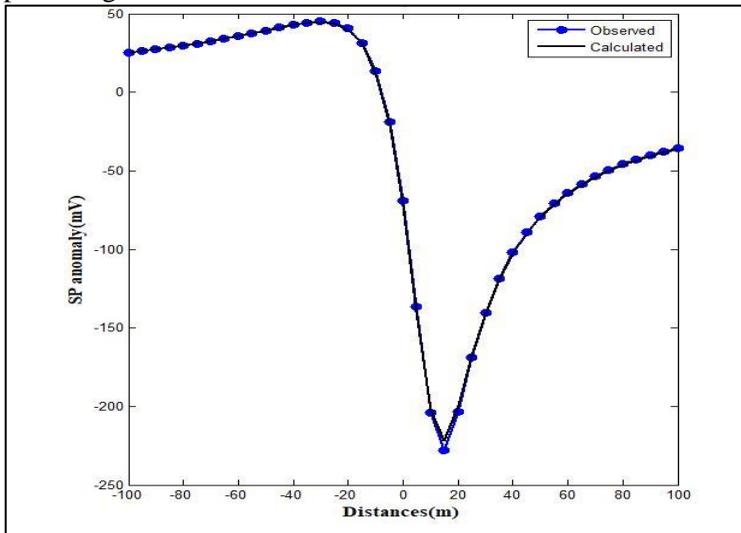
Pada proses inversi data, digunakan *software* Matlab R2013a. Tahap awal yang dilakukan adalah mencari data teoritis dengan memasukkan 5 parameter sebenarnya melalui penyelesaian pemodelan kedepan (*Forward Modelling*). Lima parameter yang digunakan yaitu, amplitude polarisasi (k), jarak dari posisi awal (D), kedalaman (h), sudut *inclined sheet* (θ), dan lebar setengah sheet (a). Nilai masing-masing parameter yaitu $k = 100$, $D = 5$ m, $h = 15$ m, $\theta = 40^\circ$, dan $a = 10$. Pada proses inversi, jumlah variasi populasi yang digunakan sebanyak 10, 15, 20, 25 dan 30, dengan maksimum gen adalah 150. Proses inversi merupakan suatu proses untuk mendapatkan solusi model dari suatu data pengukuran. Hal ini dilakukan dengan cara meminimumkan fungsi objektif yang terdapat pada Persamaan 2.5. Baik atau tidaknya hasil inversi pada umumnya dapat dilihat dari nilai misfitnya. Apabila nilai misfitnya kecil, terdapat kemungkinan solusi yang dihasilkan itu baik, begitupun sebaliknya. Akan tetapi, dalam proses inversi anomali data SP, nilai misfit yang kecil belum tentu menghasilkan solusi terbaik. Hal itu dikarenakan solusi inversi anomali SP pada dasarnya adalah unik, artinya terdapat ribuan parameter model yang dapat digunakan untuk memprediksi data tersebut. Dengan demikian, proses inversi ini membutuhkan ketidakpastian parameter model yang dapat dihasilkan dari Posterior Distribusi Model (PDM) yang diestimasi melalui algoritma *Micro-Differential Evolution*.

4.1.1 Efek Populasi

Pada proses selanjutnya, dilakukan uji populasi untuk mengetahui pengaruh banyaknya populasi terhadap solusi model terbaik. Pada proses inversi data sebagaimana pada sub-bab 4.1

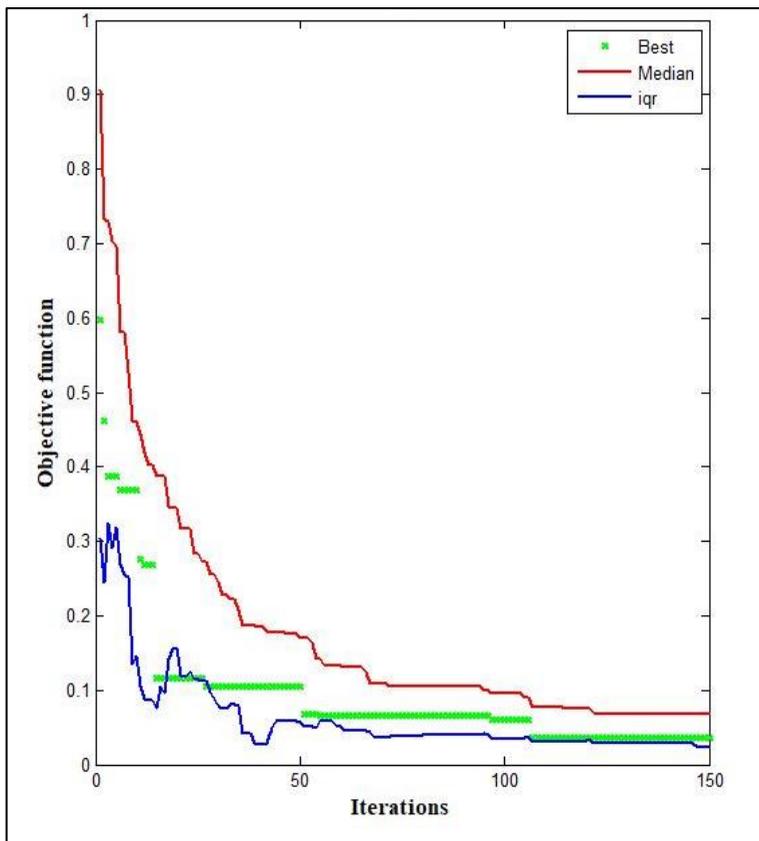
digunakan jumlah populasi sebanyak 10. Untuk uji populasi ini digunakan variasi jumlah populasi yang berbeda, yaitu 15, 20, 25, dan 30 populasi. Inversi data SP yang ditambah dengan jumlah populasi dilakukan menggunakan parameter yang sama dengan inversi data bebas noise. Begitupula dengan nilai faktor skala ($F1$) sebesar 0,5, nilai crossover sebesar 0,7, dan nilai *improvement rate* (IR) sebesar 0,2. Proses uji populasi yang pertama yaitu dengan mengubah populasi menjadi 15.

Gambar 4.1 menunjukkan hasil dari pencocokan kurva data sintetik pada tahap uji populasi dengan jumlah 15 populasi. Proses yang dilakukan untuk memperoleh hasil ini sama seperti yang sebelumnya. Hanya saja merubah jumlah populasinya menjadi 15. Dari grafik yang ditunjukkan Gambar 4.1 terlihat mulai banyaknya kecocokan antara kurva data observasi dengan hasil perhitungan. Kurva hasil inversi ini terlihat tumpang tindih yang menunjukkan bahwa algoritma MDE mampu mencapai optimum global.

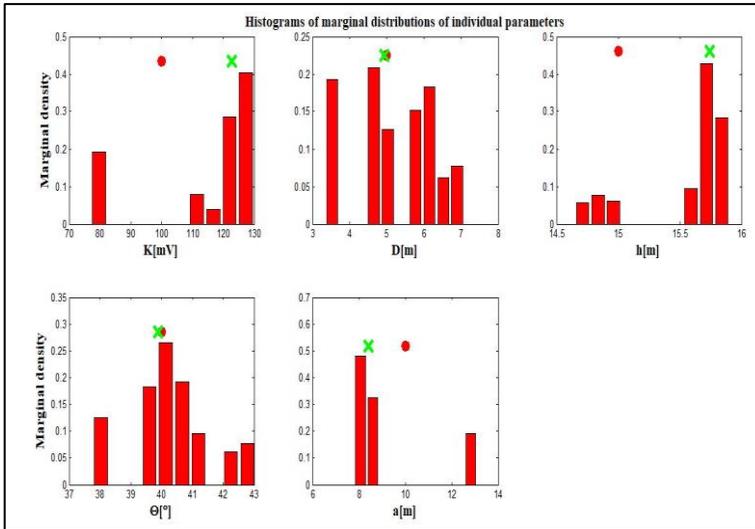


Gambar 4.1 Hasil pencocokan kurva data sintetik pada uji populasi dengan variasi 15 jumlah populasi

Setelah memperoleh hasil pencocokan kurva data observasi dengan hasil perhitungan, maka akan didapatkan nilai misfit sebagai fungsi iterasi yang ditunjukkan Gambar 4.2. Gambar 4.2 menunjukkan nilai fungsi objektif mulai stabil pada titik 0,059. Sehingga solusi model yang nilai errornya dibawah 0,059 akan dimasukkan dalam posterior distribusi model.



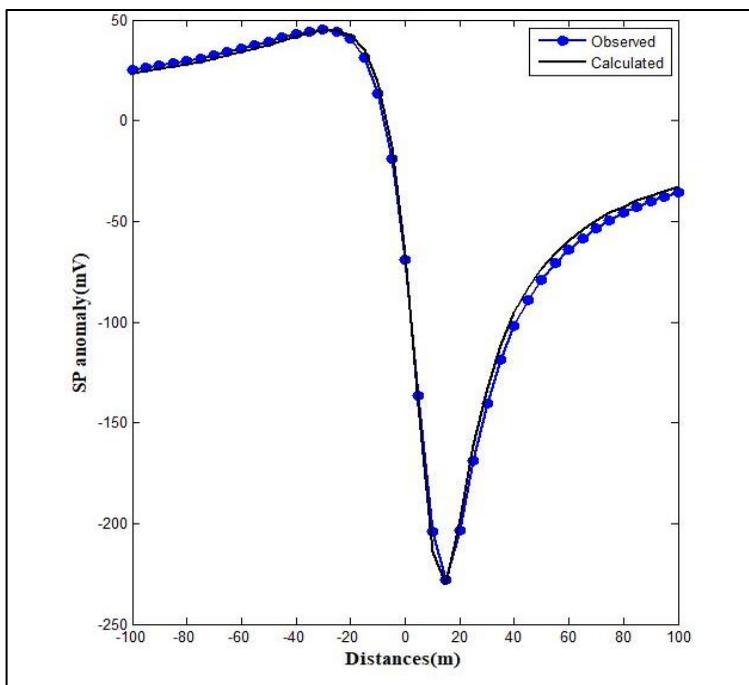
Gambar 4.2 Misfit sebagai fungsi iterasi pada inversi model data sintetik dengan jumlah populasi 15



Gambar 4.3 Posterior distribusi model untuk model sintetik data dengan jumlah populasi 15

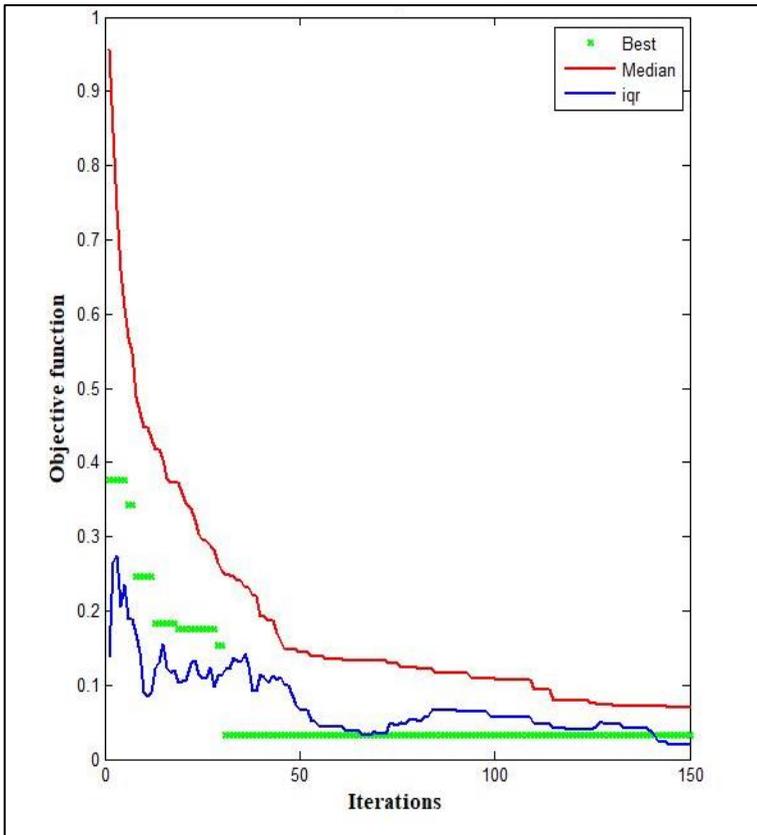
Untuk estimasi ketidakpastian dari setiap parameter model menggunakan nilai posterior distribusi model (PDM). Namun, ketidakpastian juga dapat diestimasi melalui interquartil dari PDM. Hasil posterior distribusi model ini juga berfungsi untuk mengetahui seberapa dekat nilai sebenarnya dengan hasil inversi. Selain itu, untuk mengestimasi nilai ketidakpastian model yang diperoleh dari lebar nilai interquartil. Titik yang berwarna merah pada histogram yang ditunjukkan pada Gambar 4.3 merupakan nilai yang sebenarnya yang berkorelasi dengan modus (nilai yang paling banyak muncul). Sedangkan tanda *cross* (x) merupakan nilai median dari PDM. Dari lima parameter yang digunakan, ada dua parameter yang nilai median dan nilai sebenarnya berdekatan. Sementara yang tiga lainnya saling berjauhan. Hal ini dapat disebabkan oleh jumlah populasi yang digunakan pada proses inversi.

Proses uji populasi yang kedua yaitu dengan mengubah populasi menjadi 20. Gambar 4.4 menunjukkan hasil dari pencocokan kurva data sintetik pada tahap uji populasi dengan jumlah 20 populasi. Proses yang dilakukan untuk memperoleh hasil ini sama seperti yang sebelumnya. Hanya saja merubah jumlah populasinya menjadi 20. Dari grafik yang ditunjukkan Gambar 4.4 terlihat mulai banyaknya kecocokan antara kurva data observasi dengan hasil perhitungan. Kurva hasil inversi ini terlihat tumpang tindih yang menunjukkan bahwa algoritma MDE mampu mencapai optimum global.

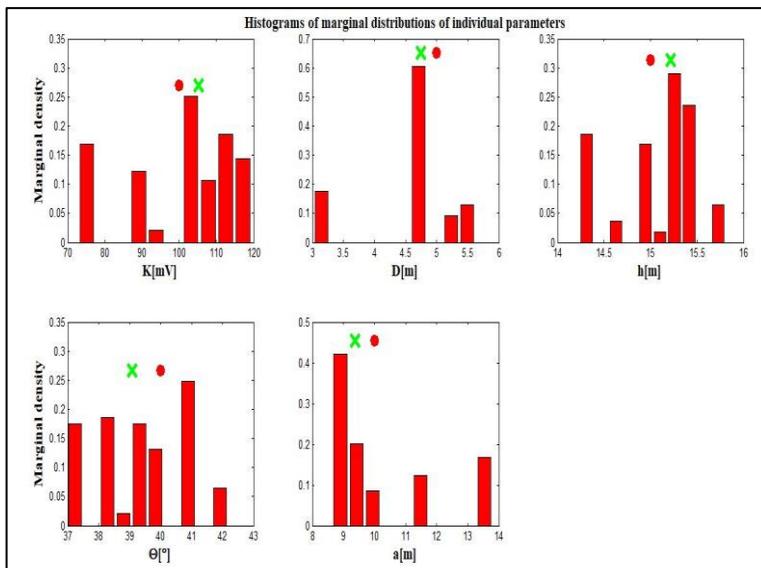


Gambar 4.4 Hasil pencocokan kurva data sintesis pada uji populasi dengan variasi 20 jumlah populasi

Setelah memperoleh hasil pencocokan kurva data observasi dengan hasil perhitungan, maka akan didapatkan nilai misfit sebagai fungsi iterasi yang ditunjukkan Gambar 4.5. Gambar 4.5 menunjukkan nilai fungsi objektif mulai stabil pada titik 0,032. Sehingga solusi model yang nilai errornya dibawah 0,032 akan dimasukkan dalam posterior distribusi model.



Gambar 4.5 Misfit sebagai fungsi iterasi pada inversi model data sintetik dengan jumlah populasi 20

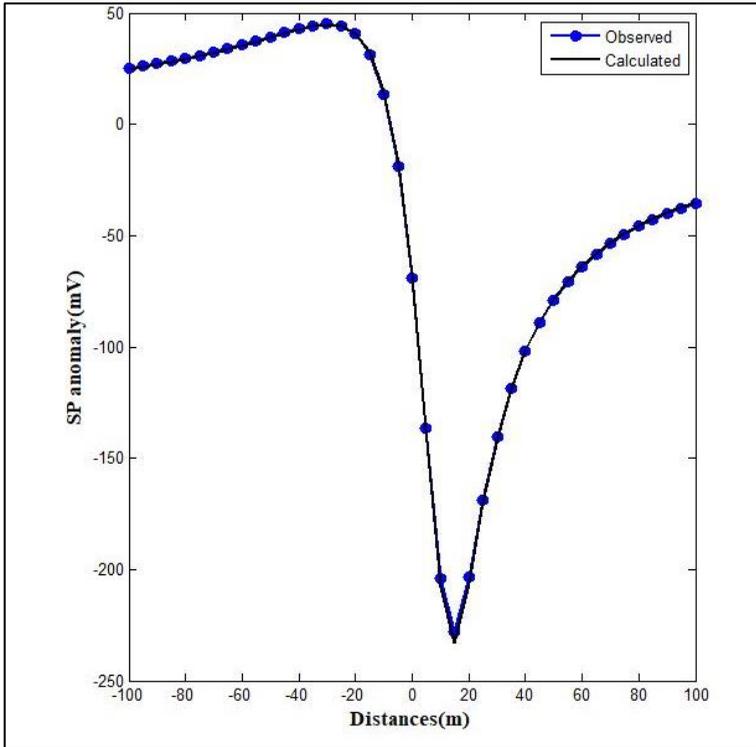


Gambar 4.6 Posterior distribusi model untuk model sintetik data dengan jumlah populasi 20

Gambar 4.6 menunjukkan hasil posterior distribusi model data sintetik dengan jumlah 20 populasi. Dari lima parameter, semua nilai median dan nilai sebenarnya saling berdekatan tetapi tidak saling berhimpit. Hal ini menunjukkan bahwa saat digunakan jumlah populasi sebanyak 20, posterior distribusi model belum menjadi solusi terbaik.

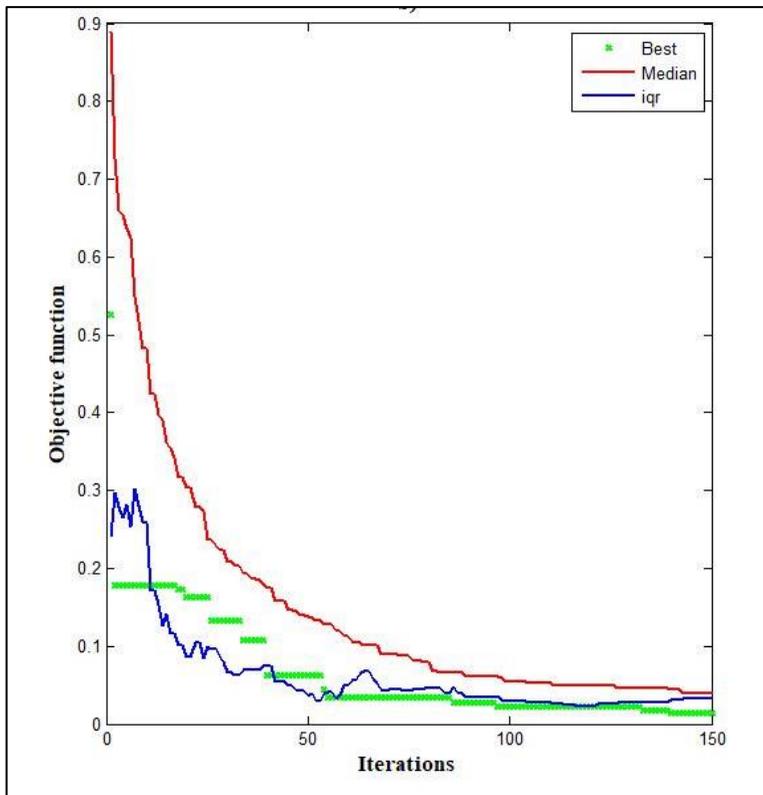
Uji populasi yang ketiga yaitu dengan mengubah jumlah populasi menjadi 25 populasi. Gambar 4.7 menunjukkan hasil dari pencocokan kurva data sintetik pada tahap uji populasi dengan jumlah 25 populasi. Proses yang dilakukan untuk memperoleh hasil ini sama seperti yang sebelumnya. Hanya saja merubah jumlah populasinya menjadi 25. Dari grafik yang ditunjukkan Gambar 4.7 terlihat mulai banyaknya kecocokan antara kurva data observasi dengan hasil perhitungan. Kurva hasil

inversi ini terlihat tumpang tindih yang menunjukkan bahwa algoritma MDE mampu mencapai optimum global.



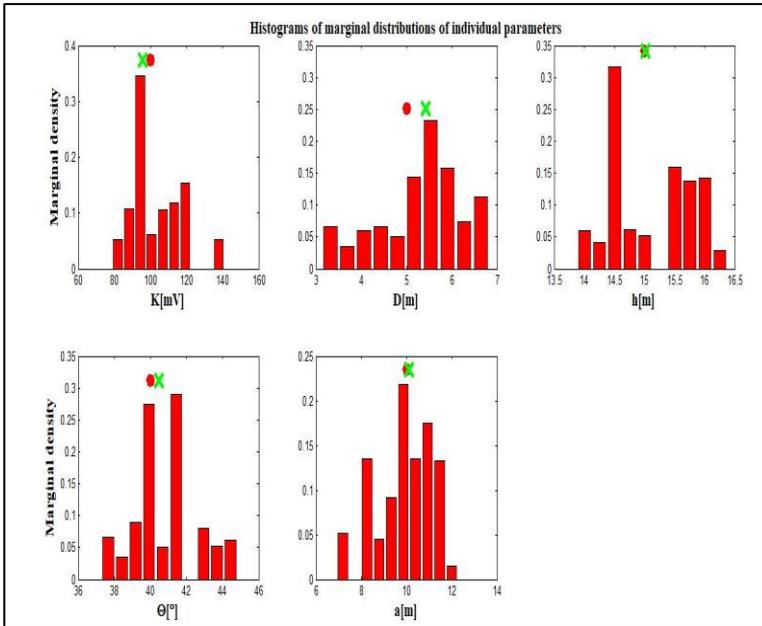
Gambar 4.7 Hasil pencocokan kurva data sintetis pada uji populasi dengan variasi 25 jumlah populasi

Setelah memperoleh hasil pencocokan kurva data observasi dengan hasil perhitungan, maka akan didapatkan nilai misfit sebagai fungsi iterasi yang ditunjukkan Gambar 4.8. Gambar 4.8 menunjukkan nilai fungsi objektif mulai stabil pada titik 0,057. Sehingga solusi model yang nilai errornya dibawah 0,057 akan dimasukkan dalam posterior distribusi model.



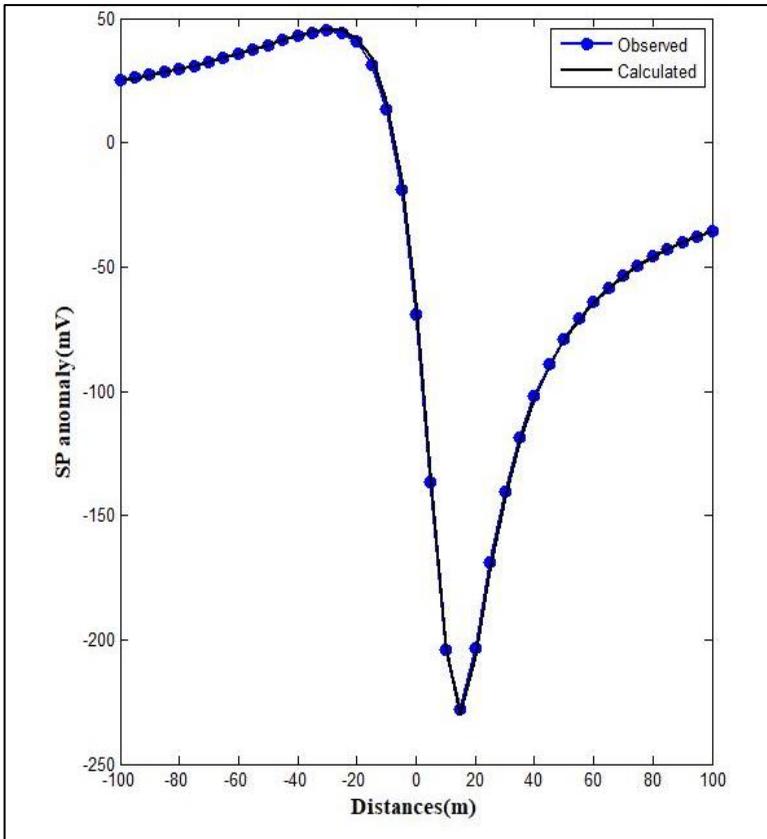
Gambar 4.8 Misfit sebagai fungsi iterasi pada inversi model data sintetik dengan jumlah populasi 25

Gambar 4.9 menunjukkan hasil posterior distribusi model data sintetik dengan jumlah 25 populasi. Dari lima parameter, ada empat nilai median dan nilai sebenarnya saling berdekatan tetapi tidak saling berhimpit. Hal ini menunjukkan bahwa saat digunakan jumlah populasi sebanyak 25, posterior distribusi model belum menjadi solusi terbaik.



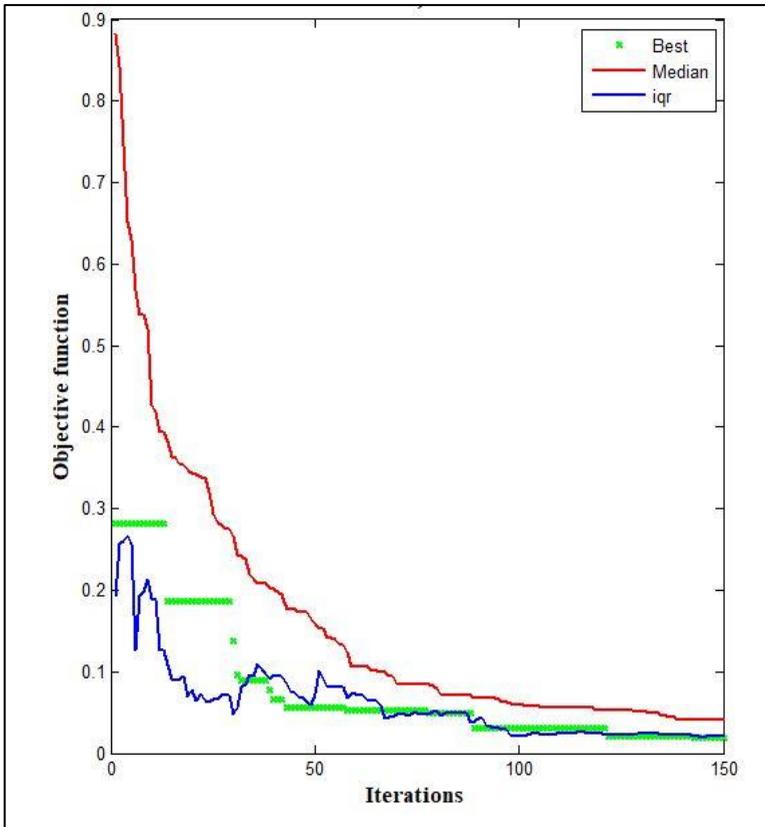
Gambar 4.9 Posterior distribusi model untuk model sintetis data dengan jumlah populasi 25

Uji populasi yang keempat yaitu dengan mengubah jumlah populasi menjadi 30. Proses inversi ini dilakukan dengan jumlah dan nilai parameter yang sama sebagaimana pada sub-bab 4.1. Gambar 4.10 menunjukkan hasil dari pencocokan kurva data sintetis pada tahap uji populasi dengan jumlah 30 populasi. Proses yang dilakukan untuk memperoleh hasil ini sama seperti yang sebelumnya. Hanya saja merubah jumlah populasinya menjadi 30. Dari grafik yang ditunjukkan Gambar 4.10 terlihat mulai banyaknya kecocokan antara kurva data observasi dengan hasil perhitungan. Kurva hasil inversi ini terlihat tumpang tindih yang menunjukkan bahwa algoritma MDE mampu mencapai optimum global.



Gambar 4.10 Hasil pencocokan kurva data sintetis pada uji populasi dengan variasi 30 jumlah populasi

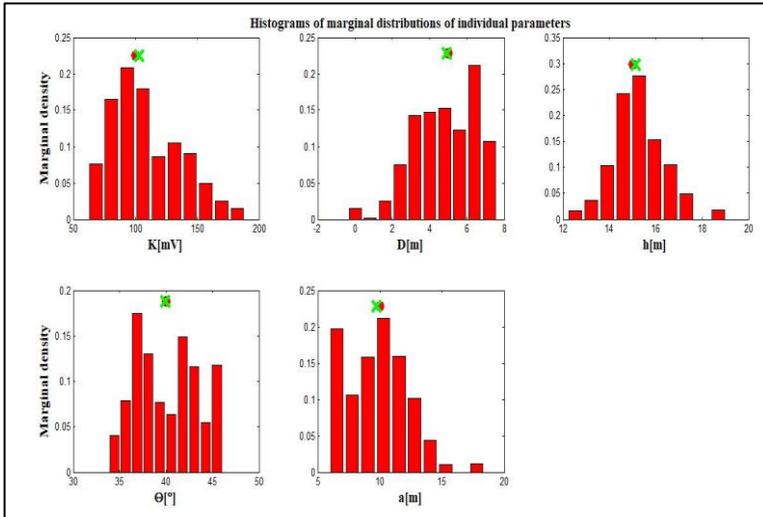
Setelah memperoleh hasil pencocokan kurva data observasi dengan hasil perhitungan, maka akan didapatkan nilai misfit sebagai fungsi iterasi yang ditunjukkan Gambar 4.11. Gambar 4.11 menunjukkan nilai fungsi objektif mulai stabil pada titik 0,032. Sehingga solusi model yang nilai errornya dibawah 0,052 akan dimasukkan dalam posterior distribusi model.



Gambar 4.11 Misfit sebagai fungsi iterasi pada inversi model data sintetik dengan jumlah populasi 30

Gambar 4.12 menunjukkan hasil posterior distribusi model untuk data yang ditambah jumlah populasinya menjadi 30. Terlihat bahwa nilai sebenarnya yang ditunjukkan oleh titik merah dan nilai median yang ditunjukkan oleh cross hijau memiliki kecocokan antara satu sama lain dari keseluruhan parameter model. Hal ini menunjukkan bahwa dengan jumlah

populasi sebanyak 30 mampu menghasilkan posterior distribusi model yang baik.



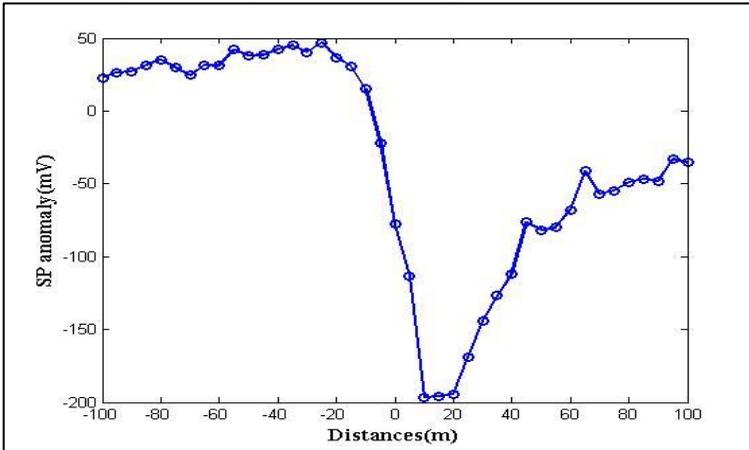
Gambar 4.12 Posterior distribusi model untuk model sintetik data dengan jumlah populasi 30

Dari uji populasi yang dilakukan dengan menggunakan variasi populasi 15, 20, 25, dan 30 menunjukkan hasil yang berbeda-beda terhadap penentuan posterior distribusi model. Solusi model terbaik adalah pada saat jumlah populasi yang digunakan sebanyak 30 populasi. Hal ini ditunjukkan pada posterior distribusi model pada Gambar 4.12. Gambar 4.12 menunjukkan antara nilai sesungguhnya dengan nilai median yang dilambangkan dengan titik merah dan tanda silang berwarna hijau saling berhimpit. Artinya, pada populasi sebanyak 30, algoritma MDE ini sudah dapat digunakan untuk inversi data *Self-Potential* (SP). Pada populasi 30, MDE dapat mencapai optimum yang baik.

4.1.2 Efek Noise

Proses pemodelan kedepan dilakukan untuk mendapatkan nilai anomali data SP yang berupa data bebas noise dan yang

ditambah noise. Gambar 4.13 merupakan hasil dari pemodelan kedepan. Proses inversi data sintetik tanpa noise dilakukan dengan range parameter yang terdapat pada Tabel 4.1. Proses ini menggunakan nilai faktor skala ($F1$) sebesar 0,5, nilai crossover sebesar 0,7, dan nilai *improvement rate* (IR) sebesar 0,2. Nilai ini digunakan berdasar pada data teoritis untuk proses pengolahan data menggunakan algoritma *Micro-Differential Evolution*.



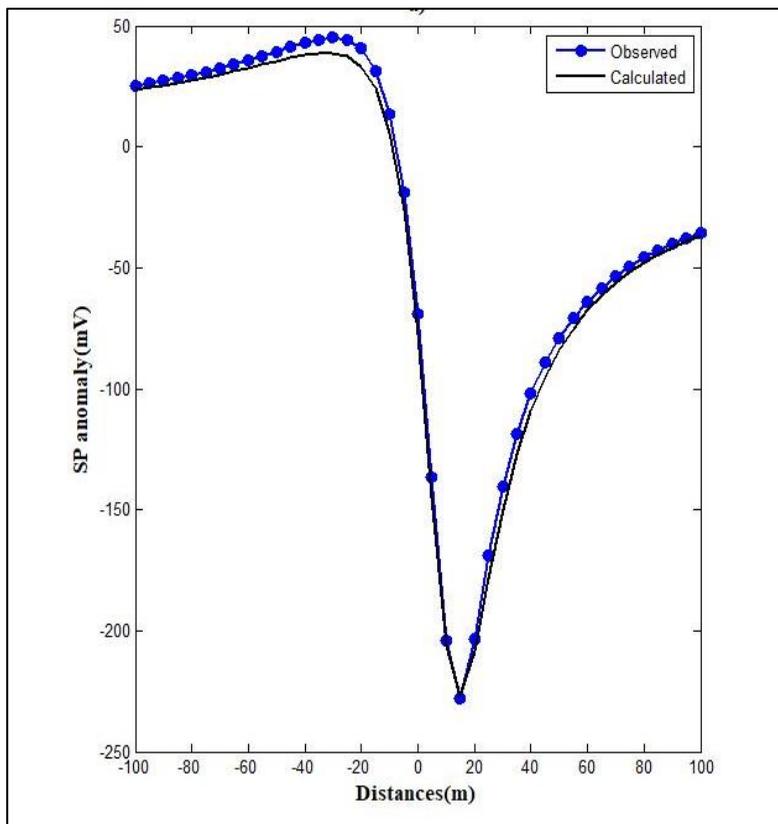
Gambar 4.13 Hasil pemodelan kedepan dari data sintetik tanpa noise

Tabel 4.1 Hasil inversi data

Parameter	TRUE	Range	Hasil Inversi	
			Median	Interquartil
K (mV)	100	10 - 200	77,681	19,726
D (m)	5	(-100) - 100	3,871	1,817
h (m)	15	5 -- 40	14,742	4,117
α (°)	40	10 -100	38,315	10,930
a (m)	10	2 -- 30	12,902	2,877

Selanjutnya, adalah proses pencocokan kurva dari data observasi dengan hasil perhitungan yang ditunjukkan pada Gambar 4.14 dan misfit sebagai fungsi iterasi sebagaimana pada Gambar 4.15. Gambar 4.14 menunjukkan bahwa perhitungan yang dilambangkan garis berwarna hitam berhimpit dengan data

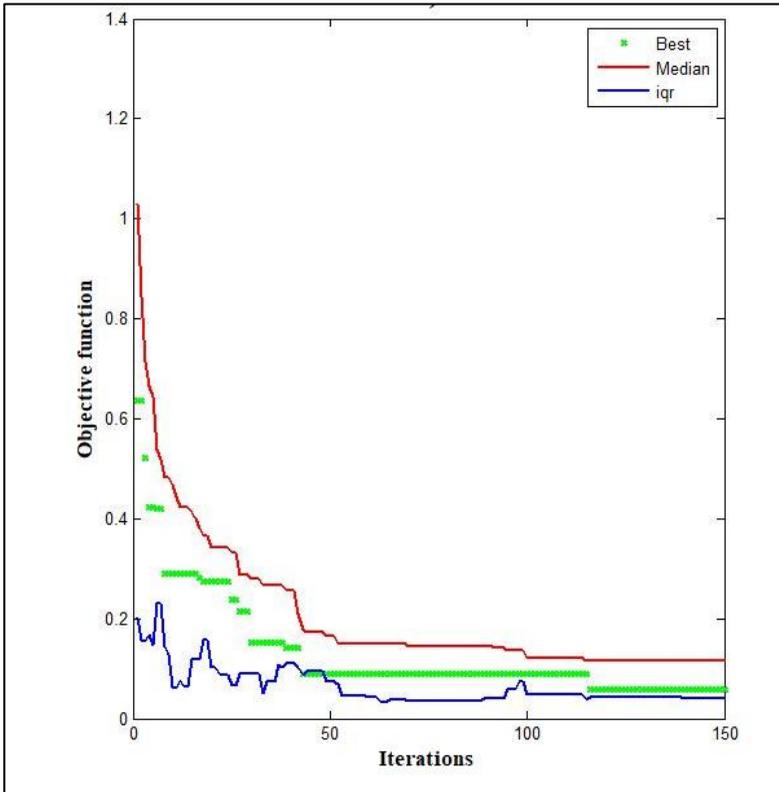
observasi yang dilambangkan dengan titik berwarna biru. Kurva hasil inversi yang tumpang tindih menunjukkan bahwa algoritma MDE ini mampu mencapai optimum global.



Gambar 4.14 Hasil pencocokan kurva data sintetik tanpa noise

Terdapat 3 jenis garis pada Gambar 4.15 yaitu, garis yang berwarna hijau mewakili nilai error fungsi objektif, garis yang berwarna merah merupakan median, dan garis yang berwarna biru merupakan interkuartil. Gambar 4.15 menunjukkan bahwa nilai error fungsi objektif stabil disekitar 0,1364 dan akan lurus apabila

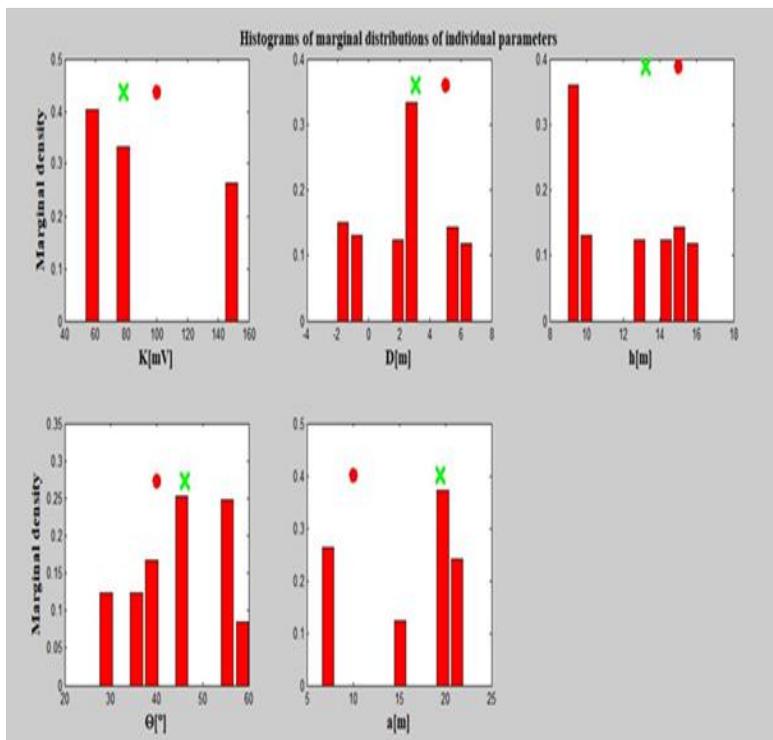
sudah konvergen. Maka titik itu dijadikan sebagai *objective cut off*. Sehingga solusi model yang nilai errornya dibawah 0,1364 dimasukkan dalam posterior distribusi model.



Gambar 4.15 Misfit sebagai fungsi iterasi pada inversi model sintetik

Nilai median yang ditunjukkan oleh garis berwarna merah pada Gambar 4.15 berfungsi untuk penebakan parameter model yang bagus. Ada perubahan yang terjadi sebelum iterasi ke 50. Memasuki iterasi ke 50, garis mulai stabil. Begitu pula untuk nilai interquartil yang ditunjukkan oleh garis berwarna biru. Range interquartil merupakan ukuran dari persebaran statistik. Interquartil akan bersifat eksploratif apabila grafik yang ditunjukkan naik turun atau tidak stabil. Ciri-ciri interquartil yang

bersifat eksploratif yaitu grafiknya tidak cepat konvergen, ada kemungkinan terjebak pada minimum lokal, tetapi mampu keluar dari minimum lokal dengan cepat. Interkuartil juga bisa bersifat eksploitatif apabila grafik yang ditunjukkan relatif stabil. Ciri-ciri interkuartil yang bersifat eksploitatif adalah grafik cepat konvergen, namun tetap ada kemungkinan terjebak pada minimum lokal. Pada saat proses memasuki iterasi ke 50, nilai error fungsi objektif, nilai median, dan nilai interkuartil cenderung relatif stabil. Artinya, algoritma *Micro-Differential Evolution* ini seimbang.



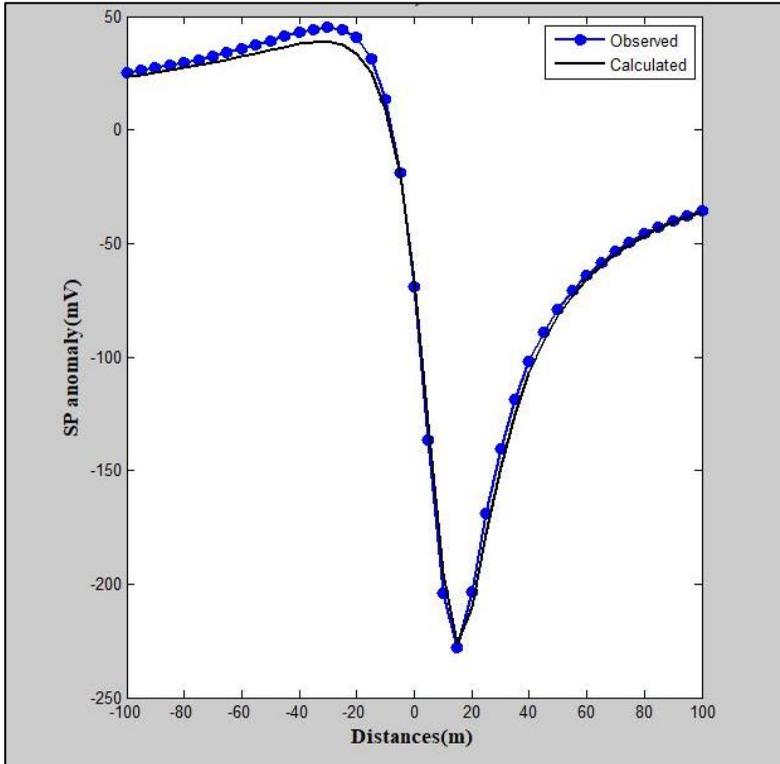
Gambar 4.16 Posterior distribusi model untuk model sintetik data tanpa noise (Titik merah menunjukkan nilai sebenarnya, tanda silang (x) menunjukkan median dari PDM)

Untuk estimasi ketidakpastian dari setiap parameter model menggunakan nilai posterior distribusi model (PDM). Namun, ketidakpastian juga dapat diestimasi melalui interkuartil dari PDM. Hasil posterior distribusi model ini juga berfungsi untuk mengetahui seberapa dekat nilai sebenarnya dengan hasil inversi. Selain itu, untuk mengestimasi nilai ketidakpastian model yang diperoleh dari lebar nilai interkuartil. Titik yang berwarna merah pada histogram yang ditunjukkan pada Gambar 4.16 merupakan nilai yang sebenarnya yang berkorelasi dengan modus (nilai yang paling banyak muncul). Sedangkan tanda silang (x) merupakan nilai median dari PDM. Dari 5 parameter yang digunakan, ada 4 parameter yang nilai median dan nilai sebenarnya berdekatan. Artinya, algoritma *Micro-Differential Evolution* ini akurat untuk digunakan dalam mengestimasi PDM untuk menghasilkan solusi model terbaik dari data *Self-Potential (SP)*. Sedangkan 1 parameter lainnya memiliki titik yang berjauhan antara nilai median dengan nilai yang sebenarnya. Hal ini disebabkan oleh sedikitnya populasi yang digunakan pada proses inversi.

Setelah dilakukan proses inversi data SP bebas noise, algoritma MDE digunakan untuk proses inversi data SP yang dengan noise. Hal ini dilakukan untuk mengetahui kemampuan algoritma MDE untuk proses inversi data SP. Inversi data SP yang dengan noise dilakukan menggunakan parameter yang sama dengan inversi data bebas noise. Begitupula dengan nilai faktor skala (F1) sebesar 0.5, nilai crossover sebesar 0.7, dan nilai *improvement rate (IR)* sebesar 0.2. Dari proses ini, dapat dilihat bagaimana pengaruh noise terhadap kecocokan kurva data sintetik.

Gambar 4.17 merupakan hasil pencocokan kurva antara data observasi dengan perhitungan. Dari kurva ini menunjukkan

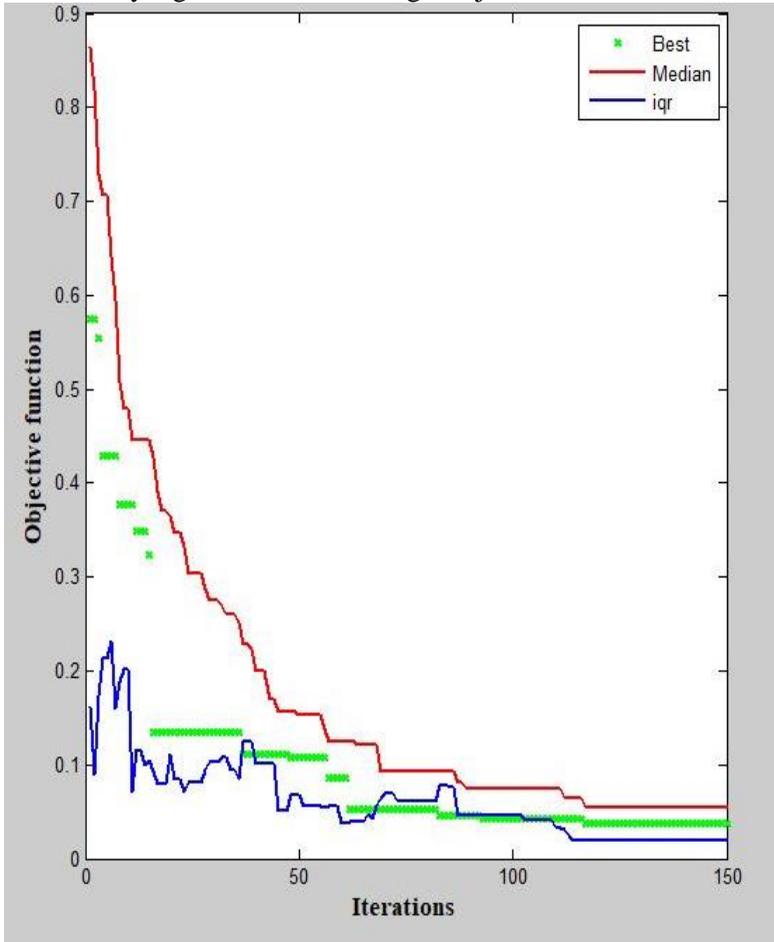
bahwa hasilnya terdapat beberapa titik yang tidak cocok. Hal ini dikarenakan adanya anomali pada data SP. Ketidaccocokan antara data observasi dan data perhitungan juga dapat dilihat dari grafik error sebagaimana Gambar 4.18.



Gambar 4.17 Hasil pencocokan kurva data sintetik dengan noise

Penambahan error sebesar 10% terlihat mempengaruhi tingkat kecocokan kurva antara data observasi dan hasil perhitungan. Ada beberapa titik yang keluar dari garis hitam. Ketidaccocokan hasil ini juga akan mempengaruhi nilai misfit yang ditunjukkan Gambar 4.18. Gambar 4.18 menunjukkan bahwa nilai fungsi objektifnya bertambah jika dibandingkan dengan Gambar 4.15. Artinya, terdapat perubahan nilai fungsi objektif akibat dari

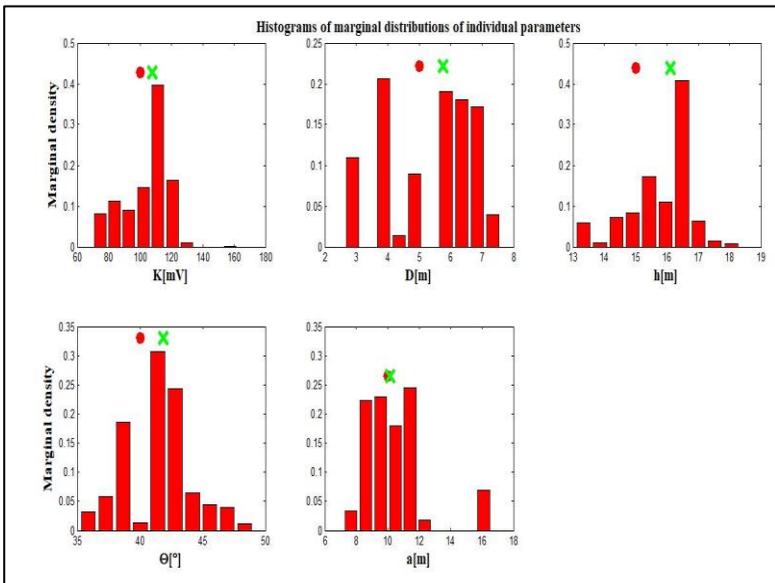
penambahan noise. Sehingga noise ini akan mempengaruhi pula untuk solusi model terbaiknya. Untuk solusi terbaiknya digunakan PDM. Posterior distribusi model dalam proses ini diestimasi yang memiliki nilai fungsi objektif dibawah 0,146.



Gambar 4.18 Misfit sebagai fungsi iterasi pada inversi model sintetik dengan noise

Setelah iterasi ke 50 nilai fungsi objektif pada Gambar 4.18 baru mulai stabil. Hal ini berarti penambahan error sebesar juga mempengaruhi kestabilan suatu kurva. Noise tersebut akan mempengaruhi solusi terbaiknya juga.

Gambar 4.19 menunjukkan hasil posterior distribusi model untuk data dengan noise. Terlihat bahwa nilai sebenarnya yang ditunjukkan oleh titik merah dan nilai median yang ditunjukkan oleh cross hijau terdapat sedikit jarak dari beberapa parameter model.



Gambar 4.19 Posterior distribusi model untuk model sintetik data dengan noise (Titik merah menunjukkan nilai sebenarnya, tanda silang (x) menunjukkan median dari PDM)

Tabel 4.2 merupakan hasil inversi data sintetik yang ditambah noise. Dari hasil interquartil dari PDM, nilai yang dihasilkan mengalami peningkatan apabila dibandingkan dengan

data sintetik bebas noise pada beberapa parameter model. Selain itu, nilai median yang dihasilkan jauh berbeda dari nilai sebenarnya, jika dibandingkan dengan median dari inversi data tanpa noise.

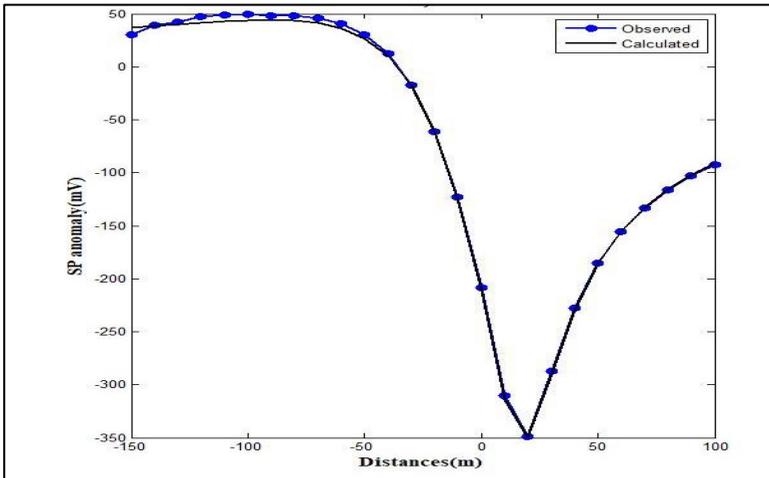
Tabel 4.2 Hasil inversi data sintetik ditambah noise

Parameter	TRUE	Range	Hasil Inversi	
Model		Parameter	Median	Interkuartil
K (mV)	100	10 - 200	84,459	57,354
D (m)	5	(-100) - 100	4,372	4,523
h (m)	15	5 -- 40	14,995	6,417
α (°)	40	10 -100	46,679	15,484
a (m)	10	2 -- 30	15,952	9,097

4.2 Data Lapangan

Setelah dilakukan uji kelayakan algoritma *Micro-Differential Evolution* pada inversi data sintetik, maka algoritma ini diterapkan pada proses inversi data lapangan. Data lapangan yang digunakan yaitu data lapangan khayangan api Bojonegoro.

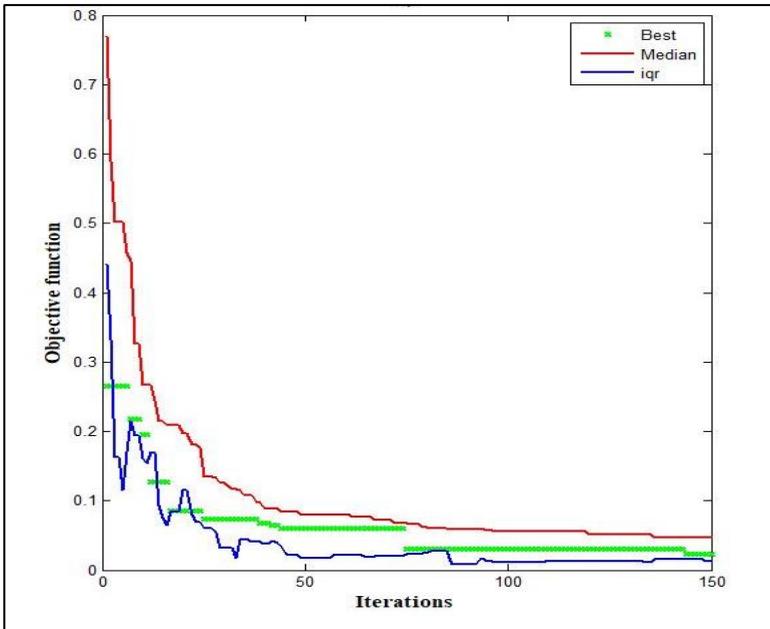
i



Gambar 4.20 Hasil pencocokan kurva SP khayangan api Bojonegoro

Pada tahap ini, dilakukan proses yang sama seperti inversi data sintetik. Sehingga didapatkan kurva pencocokan antara data observasi dan perhitungan sebagaimana pada Gambar 4.20. Gambar 4.20 menunjukkan bahwa kurva data observasi dan perhitungan berhimpit. Namun ada juga beberapa titik yang tidak cocok antara data observasi dengan hasil perhitungan.

Sedangkan untuk nilai *objective cut off*nya, nilai errornya stabil dibawah 0,060 sesuai pada Gambar 4.21. Nilai error tersebut konstan mulai dari iterasi sekitar 30 hingga iterasi 150. Sehingga semua model dibawah nilai *objective function* 0,060 dimasukkan dalam posterior distribusi model sebagaimana pada Gambar 4.22. Posterior distribusi model tersebut menghasilkan nilai median dan nilai interkuartil dari data anomali kayangan api sebagaimana pada Tabel 4.3.

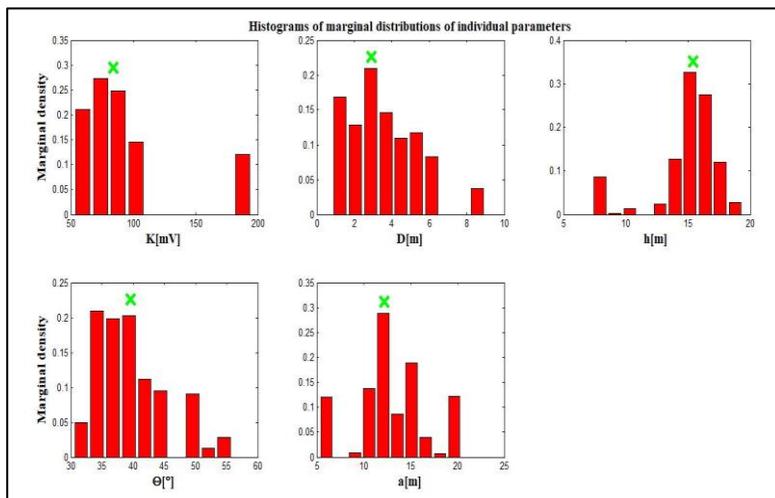


Gambar 4.21 Misfit sebagai fungsi iterasi data lapangan kayangan api Bojonegoro

Hasil histogram posterior distribusi model ditunjukkan pada Gambar 4.16 untuk semua parameter model. Nilai interkuartil menunjukkan derajat ketidakpastian dari solusi model yang telah dihasilkan. Interquartile yang didapat dari proses inversi data kayangan api, menunjukkan nilai yang kecil. Sehingga mengakibatkan ketidakpastian dari solusi juga kecil. Dan itu menandakan bahwa anomali SP berupa *inclined sheet* kemungkinan besar terletak pada nilai median tersebut.

Perbandingan hasil inversi data lapangan Khayangan Api Bojonegoro menggunakan algoritma MDE, FPA, dan CWT dapat dilihat pada Tabel 4.3. Tabel 4.3 menunjukkan hasil inversi data lapangan menggunakan beberapa metode. Hasil kedalaman dari *inclined sheet* ini hampir sama dengan hasil penelitian yang telah dilakukan oleh Fairus (2017). Dimana penelitian tersebut untuk identifikasi rekahan sebagai jalan keluarnya gas kayangan api

dengan menggunakan data SP. Pengolahan data yang telah dilakukan oleh Fairus (2017) menggunakan *Continuous Wavelet Transform* (CWT) untuk mengidentifikasi kedalaman rekahan tersebut. Kedalaman yang dihasilkan oleh Fairus (2017) berkisar 15,08 m. Sehingga inversi data lapangan ini sesuai dengan kondisi geologi kayangan api.



Gambar 4.22 Posterior distribusi model untuk data lapangan khayangan Bojonegoro

Tabel 4.3 Perbandingan Hasil Inversi Data Lapangan Kayangan Api Bojonegoro

Parameter Model	Range Parameter	Hasil Inversi FPA		Hasil Inversi MDE		Hasil Inversi CWT
		Median	Interkuartil	Median	Interkuartil	
K (mV)	10 - 200	85,81	28,23	98,07	40,14	29,21
D (m)	(-100) - 100	4,783	2,502	1,31	4,77	8,68
h (m)	5 -- 40	15,84	1,115	31,77	2,79	15,08
α ($^{\circ}$)	10 -100	43,55	4,322	48,04	3,75	42,58
a (m)	2 -- 30	13,57	4,853	28,23	6,02	25,13

“Halaman ini sengaja dikosongkan”

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil analisa data dan pembahasan, dapat disimpulkan bahwa:

1. Algoritma *Micro-Differential Evolution* mampu menyediakan Posterior Distribusi Model untuk inversi anomali SP dengan populasi 30 model *inclined sheet* 2D dengan cepat dan hasil inversi data SP akurat untuk data sintetik.
2. *Micro-Differential Evolution* akurat untuk inversi data SP (data sintetik dan data lapangan) yang telah dibandingkan dengan beberapa penelitian sebelumnya.

5.2 Saran

Berdasarkan hasil analisa data dan pembahasan dari tugas akhir ini, untuk penelitian kedepan, penulis menyarankan inversi data *self potential* dengan menggunakan algoritma optimasi yang lain.

“Halaman ini sengaja dikosongkan”

DAFTAR PUSTAKA

- Davydov, A.Ya., 1961. Positive Self-Potential Anomalies Over Sulfe Bodies. *Sovetskaya Geologiya*.
- Fagerlund, F., Heinson, G., 2003. Detecting subsurface groundwater flow in fractured rock using self-potential (SP) methods. *Environ. Geol.* 43, 782–794.
- J. Brest, S. Greiner, B. Boškovi'c, M. Mernik, V.Žumer (2006) Self-Adapting Control Parameters in Differential Evolution: A Comparative Study on Numerical Benchmark Problems, *IEEE Transactions on Evolutionary Computation*, vol. 10, no. 6, pp. 646–657.
- Mauri, G., Williams-Jones, G., Saracco, G., 2010. Depth determinations of shallow hydrothermal systems by self-potential and multi-scale wavelet tomography. *J. Volcanol. Geotherm. Res.* 191, 233–244. doi:10.1016/j.jvolgeores.2010.02.004
- Ren, X., Chen, Z. z, Ma, Z., 2010. Differential Evolution Using Smaller Population, in: 2010 Second International Conference on Machine Learning and Computing. Presented at the 2010 Second International Conference on Machine Learning and Computing, pp. 76–80. doi:10.1109/ICMLC.2010.9
- Revil, A., Jardani, A., 2013. The self-potential method: theory and applications in environmental geosciences. Cambridge University Press, Cambridge. John Wiley and Sons Ltd, Chichester, 796 pp, first edition
- Reynolds, John., 1997. An Introductions to Applied and Enviromental Geophysics. Singapore: John Willey and Sons.
- Sato, M., Mooney, H.M., 1960. The electrochemical mechanism of sulphide self-potentials. *Geophysics XXV*.
- Sharma, P.V., 1997, *Environmental and Geophysics*, Cambridge University Press. New York.London. Melbourne

Telford, W.M., Geldart, L.P., Sheriff, R.E., and Keys, D.A., 1990.
Applied Geophysics, Cambridge, University Press Cambridge.

LAMPIRAN

LAMPIRAN A *Algoritma Micro-Differential Evolution*

```
clc;clear all;close all
global Xmax Xmin x v_exp F1 pop nvars Cr
Rnoise=xlsread('data forward.xlsx',1);
%data=xlsread('data.xls');
x=Rnoise(:,1);v_exp=Rnoise(:,2);
MaxGen=150;
pop=10;
% inisialisasi awal
Pmin=[10];Pmax=[200];
Dmin=[min(x)];Dmax=[max(x)];
hmin=[5];hmax=[40];
thetamin=[10];thethamax=[100];
amin=[2];
amax=[30];
Xmin=[Pmin Dmin hmin thetamin amin];
Xmax=[Pmax Dmax hmax thethamax amax];

% Initial values of an array
nvars=length(Xmax);
%crossover=0.8;gam=0.1;
F1=0.5;
Cr=0.7;
IR=0.2;
tau=0.2*(Xmax-Xmin);
% -----
--
% generating the initial locations of n
fireflies
X=init_MDE(pop,nvars);
% xpos=[Xnew Lightn];
V=forwardpop(X);
Y=objfunc(V);
Xb=X;Yb=Y;

[fmin,I]=min(Y);
best=X(I,:);
```

```

Xbest=best;
solution(1,:)=Xbest;
errorbest(1,1)=fmin;
me(1,1)=median(Y);
fiqr(1,1)=iqr(Yb);
xpos=[];
% Iterations or pseudo time marching
for k=1:MaxGen,      %%%% start iterations
    % This line of reducing alpha is optional
    X=MDE_move(X,Xb,tau,IR);
    X=limit(Xmin,Xmax,X);
    V=forwardpop(X);
    f=objfunc(V);
    % search optimum local
    [Xb,Yb,Ir]=optimumlocal(Xb,X,Yb,f);
    IR=Ir/pop;
    X=Xb;
    Y=Yb;
    xpos=[xpos;Xb Yb];
    me(k+1,1)=median(Y);
    iqry(k+1,1)=iqr(Y);
    % search optimum global
    [GYbest,indexgbest]=min(Yb);
    gbest=indexgbest(1);
    Xbest=Xb(gbest,:);
    solution(k+1,:)=Xbest;
    errorbest(k+1,1)=GYbest;
    fiqr(k+1,1)=iqr(Yb);
    fprintf('Iteration=%i Min Error=%.2f
Individu Ke--=%.2f \n',k+1,GYbest,gbest)
    % Move all fireflies to the better locations
end %%%% end of iterations
Vbest=SPANomalies(Xbest);
mf=misfit(Vbest)
figure
subplot(1,2,1)
plot(x,v_exp,'-
o','linewidth',2,'MarkerFaceColor','b')
hold on
plot(x,Vbest,'k-','linewidth',2)

```

```

ylabel('SP
anomaly(mV)', 'fontsize', 12, 'fontweight', 'bold', '
fontname', 'Times')
xlabel('Distances(m)', 'fontsize', 12, 'fontweight'
, 'bold', 'fontname', 'Times')
legend('Observed', 'Calculated')
title('a)', 'fontsize', 12, 'fontweight', 'bold', 'fo
ntname', 'Times')
subplot(1,2,2)
plot(1:MaxGen+1, errorbest, 'gx', 'linewidth', 2)
hold on
plot(1:MaxGen+1, me, 'r-', 'linewidth', 2)
plot(1:MaxGen+1, fiqr, 'b-', 'linewidth', 2)
xlim([0 MaxGen])
% xlabel 'Iteration'
% ylabel 'RMSE'
title('b)', 'fontsize', 12, 'fontweight', 'bold', 'fo
ntname', 'Times')
ylabel('Objective
function', 'fontsize', 12, 'fontweight', 'bold', 'fon
tname', 'Times')
xlabel('Iterations', 'fontsize', 12, 'fontweight', '
bold', 'fontname', 'Times')
legend('Best', 'Median', 'iqr')
figure
for ii=1:nvars
    subplot(2,3,ii)
    hist(xpos(:,ii));
    k(ii)=median(xpos(:,ii));
    l(ii)=iqr(xpos(:,ii));
end
save sintetik.mat

```

LAMPIRAN B Algoritma Posterior Distribusi Model

```

clc;close all;clear all
Xtrue=[100 5 15 40 10]
% Xtrue=[100 5 15 40 10]
load sintetik.mat

Pars=xpos (xpos (:,end)<0.13,1:end-1);
% [m1 m2]=size(Pars);
% Pars1=zeros(m1,m2);
% Pars1(:,1)=Pars(:,1);
% Pars1(:,2)=(Pars(:,2)+Pars(:,4))/2;
% Pars1(:,3)=(Pars(:,3)+Pars(:,5))/2;
% Pars1(:,5)=0.5*((Pars(:,5)-
Pars(:,3)).^2+(Pars(:,4)-Pars(:,2)).^2).^0.5;
% for ii=1:m1
%     Pars1(ii,4)=acos((Pars(ii,4)-
Pars(ii,2))/(2*Pars1(ii,5)))*180/pi;
% end
% Pars=Pars1;
Mean=median(Pars);
[p,kl]=min(xpos(:,end));
MAP=xpos(kl,1:end-1);
STD=iqr(Pars);
t = 3;
errorbest(1,1)=fmin;
me(1,1)=median(Y);
if rem(nvars,t)==0;
    r =fix(nvars/t);
else
    r=fix(nvars/t)+1
end
k=fix(nvars/2);
% How many figures do we need to create with
this layout?
N_fig = ceil(nvars/ (r * t) ); counter = 1; j =
1;
% Open new figure
figure;

```

```

% Now plot each parameter
while counter <= nvars
    % Check whether to open a new figure?
    % Now create histogram
    [N,X] = hist(Pars(:,counter));
    Mode(counter)=mode(X);
    % And plot histogram in red
    %     if rem(nvar,t)~=0 & counter>=nvar;
    %         subplot(r,t,j+1),bar(X,N/sum(N),'r');
hold on;
    %     else
    %
    %     end
    subplot(r,t,j),bar(X,N/sum(N),'r'); hold on
    % --> can be scaled to 1 if using
"trapz(X,N)" instead of "sum(N)"!
    %     if j == 1,
    %         % Add title
    %         title('Histograms of marginal
distributions of individual
parameters','fontsize',14,'fontweight','bold','f
ontname','Times');
    %     end;
    % Add x-labels
    if counter==1;
        evalstr = strcat('K[mV]');
xlabel(evalstr,'fontsize',14,'fontweight','bold'
,'fontname','Times');
    elseif counter==2;
        evalstr = strcat('D[m]');
xlabel(evalstr,'fontsize',14,'fontweight','bold'
,'fontname','Times');
    elseif counter==3
        evalstr = strcat('h[m]');
xlabel(evalstr,'fontsize',14,'fontweight','bold'
,'fontname','Times');
    elseif counter==4
        evalstr = strcat('\Theta[\circ]');
xlabel(evalstr,'fontsize',14,'fontweight','bold'
,'fontname','Times');

```

```

else
    evalstr = strcat('a[m]');
xlabel(evalstr,'fontsize',14,'fontweight','bold',
,'fontname','Times');
end
% Then add y-label (only if j == 1 or j = r;
if j == 1 || ( min(abs(j - ([1:r]*t+1))) ==
0 ),
    ylabel('Marginal
density','fontsize',14,'fontweight','bold','font
name','Times');
end;
% Now determine the min and max X values of
the plot
% minX = min(X); maxX = max(X); minY = 0;
maxY = max(N/sum(N));
minX = min([X MAP(counter) Mean(counter)
Xtrue(counter)]); maxX = max([X MAP(counter)
Mean(counter) Xtrue(counter)]); minY = 0; maxY =
max(N/sum(N));
% Now determine appropriate scales
deltaX = 0.1*(maxX - minX);
% Calculate x_min and x_max
x_min = minX - deltaX; x_max = maxX +
deltaX;
% Now determine the min and max Y values of
the plot
y_min = 0; y_max = 1.1*maxY;
% Lets add the MAP value
%
plot(MAP(counter),0.98*y_max,'bx','Markersize',1
5,'linewidth',3);

plot(Xtrue(counter),0.98*y_max,'ro','linewidth',
5,'MarkerFaceColor','r');

plot(Mean(counter),0.98*y_max,'gx','Markersize',
15,'linewidth',3);
% Adjust the axis
% axis([x_min x_max y_min y_max]);

```

```

    % Check if counter = 1,
    if counter == 2, % --> add a title for first
figure
    % Add title
        title('Histograms of marginal
distributions of individual
parameters', 'fontsize', 14, 'fontweight', 'bold', 'f
ontname', 'Times');
    end;
    % Now update the counter
    counter = counter + 1;

    % Update j
    j = j + 1;
end;
figure
subplot(1,2,1)
plot(x,v_exp, 'o', 'linewidth', 2, 'MarkerFaceColor'
, 'b')
hold on
plot(x,Vbest, 'k-', 'linewidth', 2)
ylabel('SP
anomaly(mV)', 'fontsize', 12, 'fontweight', 'bold', '
fontname', 'Times')
xlabel('Distances (m)', 'fontsize', 12, 'fontweight'
, 'bold', 'fontname', 'Times')
legend('Observed', 'Calculated')
title('a', 'fontsize', 12, 'fontweight', 'bold', 'fo
ntname', 'Times')
subplot(1,2,2)
plot(0:MaxGen,errorbest, 'gx', 'linewidth', 2)
hold on
plot(0:MaxGen,me, 'r-', 'linewidth', 2)
plot(0:MaxGen,fiqr, 'b--', 'linewidth', 2)
title('b', 'fontsize', 12, 'fontweight', 'bold', 'fo
ntname', 'Times')
ylabel('Objective
function', 'fontsize', 12, 'fontweight', 'bold', 'fon
tname', 'Times')

```

```
xlabel('Iterations','fontsize',12,'fontweight','  
bold','fontname','Times')  
legend('Best','Mean','iqr')
```

BIODATA PENULIS



Penulis “Adhistya Ratnasari” merupakan anak ke 1 dari 4 bersaudara. Lahir di Kota Surabaya pada 19 Juli 1995 dari pasangan Hadi Mulyono dan Suhartati. Pada waktu kecil penulis menempuh pendidikan formal antara lain di TK Islam Sunan Giri Malang, SDN Rangkah Kidul Sidoarjo, SMP Negeri 5 Sidoarjo, dan SMA Negeri 2 Sidoarjo. Penulis diterima di jurusan Fisika FMIPA-ITS pada tahun 2013 melalui jalur SBMPTN dan terdaftar dengan NRP 1113100070.

Selama masa perkuliahan, penulis aktif dalam berbagai kegiatan dan organisasi mahasiswa. Beberapa organisasi yang sempat ditekuni yaitu sebagai staf Departemen Dalam Negeri (DAGRI) Mahasiswa HIMASIKA ITS (2014-2015), Bendahara Umum I HIMASIKA ITS (2015-2016), serta Ketua Tim Rayon Sidoarjo pada pelaksanaan Physics Summit (2015) .

Semasa kuliah penulis juga aktif mengikuti kegiatan workshop dan seminar tingkat nasional dan internasional. Akhir kata apabila ada kritik dan saran, pembaca dapat mengirim pesan ke: adhisty70@gmail.com.

“Segala pencapaian pasti membutuhkan usaha ”

“Halaman ini sengaja dikosongkan”