

***ITEM RESPONSE MODEL***

**PINTANUGRA PERSADANTA**

**030301029X**



**UNIVERSITAS INDONESIA**

**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM**

**DEPARTEMEN MATEMATIKA**

**DEPOK**

**2008**

***ITEM RESPONSE MODEL***

**Skripsi diajukan sebagai salah satu syarat  
untuk memperoleh gelar Sarjana Sains**

**Oleh:**

**PINTANUGRA PERSADANTA**

**030301029X**



**DEPOK**

**2008**

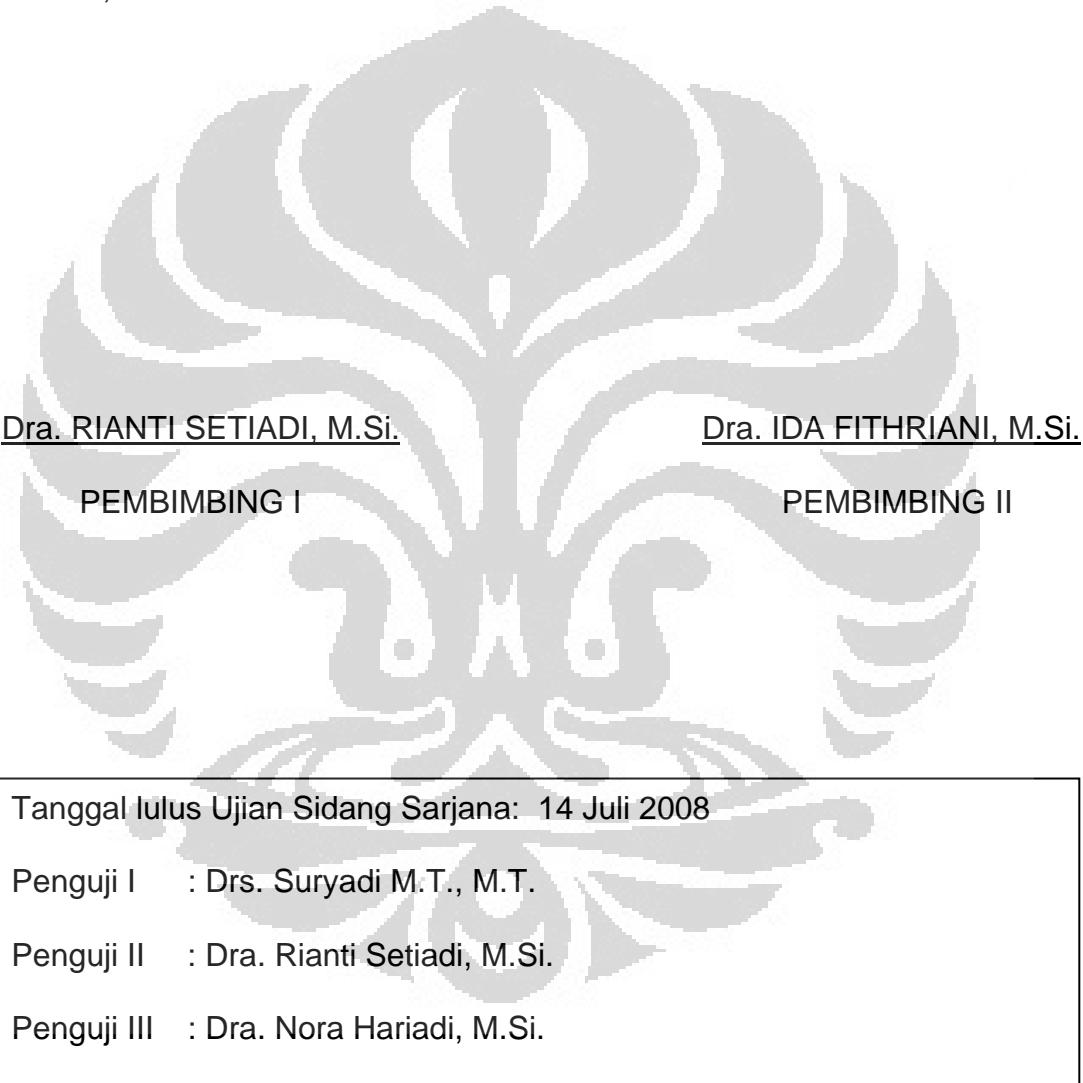
## SKRIPSI : *ITEM RESPONSE MODEL*

NAMA : PINTANUGRA PERSADANTA

NPM : 030301029X

**SKRIPSI INI TELAH DIPERIKSA DAN DISETUJUI**

DEPOK, 14 JULI 2008



## KATA PENGANTAR

Puji syukur kepada Tuhan Yesus Kristus atas segala berkat dan anugrah-Nya yang memampukan dan memberikan hikmat kepada penulis untuk menyelesaikan skripsi ini.

Penulis mengucapkan terima kasih kepada Ibu Rianti Setiadi selaku pembimbing I dan Ibu Ida Fithriani selaku pembimbing II, yang telah meluangkan waktu dan tenaga untuk membimbing penulis selama ini. Penulis juga mengucapkan terima kasih kepada Pak Gatot selaku Pembimbing Akademik, dan seluruh staf pengajar departemen Matematika FMIPA UI yang selalu tulus memberikan bekal ilmu.

Secara khusus, penulis mengucapkan terima kasih kepada kedua orang tuaku: Johanita Puspachinta Simorangkir & Perlindungan Tarigan. Makasih ya mam, pap untuk segala dukungannya, doa, dan kasih sayang selama ini. Untuk Putri & Agi, adik-adikku, terima kasih untuk kasih sayang dan keceriaan yang diberikan. Mama, Papa, Utu, dan Agi menjadi motivasi penulis menyelesaikan skripsi ini.

Ucapan terima kasih secara spesial penulis berikan kepada Reinne Natali Christine. Makasih ya Rein buat omelan dan suntikan semangat disaat malas dan atas kasih sayang dan kesetiaan yang diberikan selama ini. Satu bab lagi kita lewati. Semangat..!!

Penulis mengucapkan terima kasih kepada Kepala SMP Kristen Kalam Kudus Solo yang mengijinkan penulis menggunakan datanya untuk dipakai dalam penerapan skripsi ini.

Untuk Bembi dan Yanu terima kasih ya buat programnya. Tanpa kalian program tersebut tidak bisa jalan. Untuk Adjat dan Rieska terima kasih atas ide, kritik dan sarannya. Untuk teman-teman kumpul: Anton, Gunung, Diki, Gele, Tebe. Kapan kita main dan jalan lagi? Untuk teman2 angkatan '02, '03, dan '04 yang berjuang untuk skripsi semester ini, trima kasih ya untuk dukungannya & semangat untuk lulus dari matematika. Untuk anak '03 yang belum ambil skripsi, terus berjuang teman-teman.

Terima kasih untuk staf pengajar dan karyawan departemen Matematika yang telah membantu dalam proses belajar penulis, untuk anak Math '01, '02, '04, '05, dan '06 terima kasih untuk persahabatannya.

Akhir kata penulis mengucapkan terima kasih kepada semua pihak yang tidak bisa disebutkan satu-persatu. Semoga skripsi ini dapat bermanfaat bagi banyak orang dan dapat diambil hikmahnya. Tuhan memberkati !

Depok, Juli 2008

Penulis

## **ABSTRAK**

*Item response model* digunakan untuk menganalisa baik tidaknya soal dan menyeleksi soal-soal yang baik berdasarkan *latent ability* peserta tes dan karakteristik soal yang terdiri dari tingkat diskriminasi soal dan kesulitan soal. Dalam skripsi ini, penaksiran parameter *latent ability*, diskriminasi soal dan kesulitan soal dilakukan dengan metode penaksiran *joint maximum likelihood*, sedangkan seleksi soal dilakukan dengan menggunakan *item information function*.

Metode diatas diterapkan untuk menyeleksi soal tes Matematika semester genap tahun ajaran 2007-2008 berdasarkan jawaban siswa kelas VII SMP XYZ di kota A, pada tes tersebut. Tes terdiri dari 30 soal dan diikuti oleh 143 siswa.

Kata kunci : *item information function*, *item response model*, *joint maximum likelihood estimation*, *latent ability*, *test information function*.

vii + 73 hlm.; lamp.

Bibliografi: 7 (1983-2006)

## DAFTAR ISI

	Halaman
KATA PENGANTAR .....	i
ABSTRAK .....	iii
DAFTAR ISI .....	iv
DAFTAR GAMBAR .....	vi
DAFTAR TABEL .....	vi
DAFTAR LAMPIRAN .....	vi
BAB I. PENDAHULUAN	
1.1. Latar belakang .....	1
1.2. Perumusan masalah .....	4
1.3. Tujuan .....	4
1.4. Pembatasan masalah .....	4
1.5. Aplikasi .....	5
1.6. Sistematika penulisan .....	5
BAB II. LANDASAN TEORI	
2.1. Penaksiran <i>maximum likelihood</i> .....	7
2.2. Penaksiran <i>joint maximum likelihood</i> .....	8
2.3. <i>Fisher information</i> .....	10

### BAB III. ITEM RESPONSE MODEL

3.1.	Pengantar .....	14
3.2.	Konsep dasar IRM .....	15
3.2.1.	<i>Latent ability</i> .....	15
3.2.2.	Karakteristik soal .....	15
3.2.3.	<i>Item response curve</i> .....	16
3.3.	<i>Item Response Model</i> Untuk Sejumlah Peserta Tes	19
3.3.1.	Struktur data .....	19
3.3.2.	Asumsi model .....	20
3.4.	Estimasi parameter <i>latent ability</i> dan karakteristik soal	21
3.4.1.	Fungsi <i>likelihood</i> .....	21
3.4.2.	<i>Joint maximum likelihood estimation</i> .....	23
3.5.	Seleksi soal .....	39

### BAB IV. APLIKASI

4.1.	Data .....	44
4.2.	Analisis data .....	44

### BAB V. PENUTUP

5.1	Kesimpulan .....	50
5.2	Saran .....	50

DAFTAR PUSTAKA .....	52
----------------------	----

LAMPIRAN .....	53
----------------	----

## DAFTAR GAMBAR

Gambar	Halaman
1. Item response curve .....	17
2. Item response curve dari tiga soal dengan tingkat kesulitan berbeda .....	17
3. Item response curve dari tiga soal dengan tingkat diskriminasi berbeda .....	19

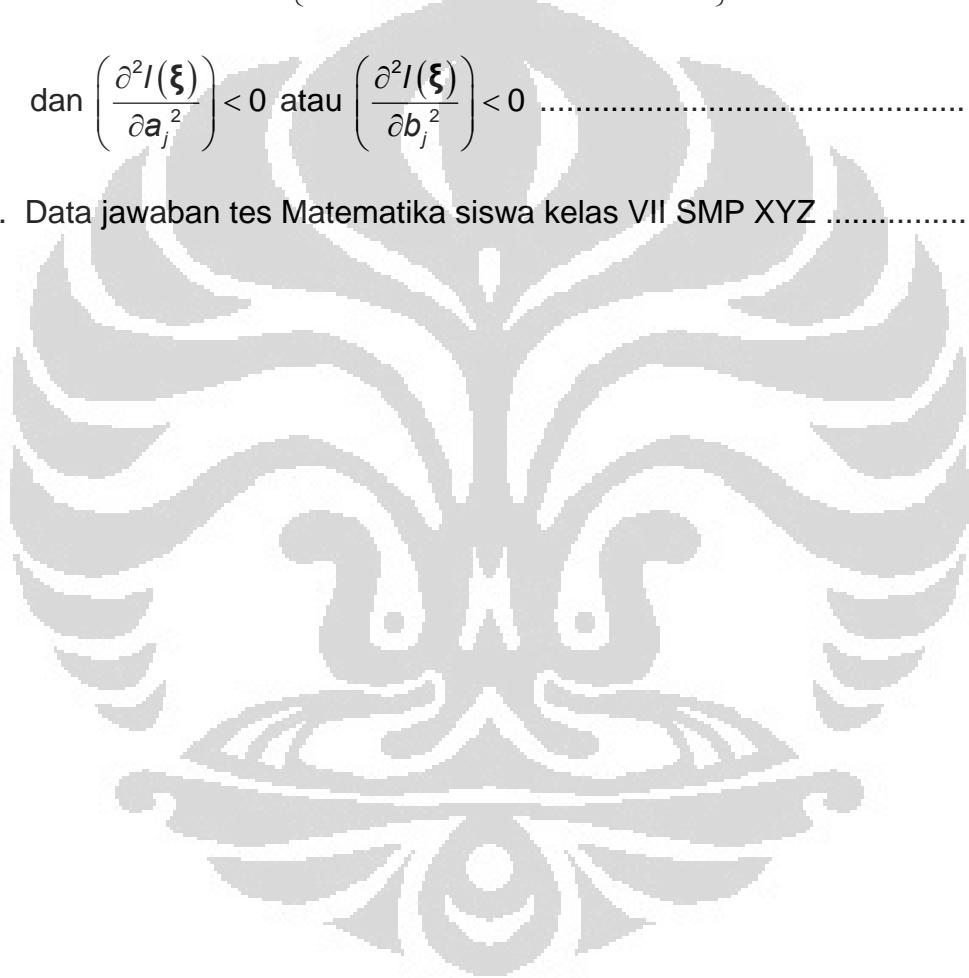
## DAFTAR TABEL

Tabel	Halaman
1. Taksiran parameter <i>latent ability</i> .....	45
2. Taksiran parameter diskriminasi soal dan kesulitan soal .....	46
3. Test information function peserta tes .....	47
4. Item information function untuk $\theta = -0,478$ .....	48
5. Item information function untuk $\theta = -0,478$ yang diurutkan .....	49

## DAFTAR LAMPIRAN

Lampiran	Halaman
1. Menunjukkan $\theta$ memaksimumkan $L(\theta) \leftrightarrow \theta$ memaksimumkan $\ln L(\theta)$ .....	53

2. Menunjukkan $\theta$ memaksimumkan $L(\theta) \leftrightarrow \theta$ memaksimumkan $\ln L(\theta), \theta = (\theta_1, \theta_2, \dots, \theta_n)$ .....	54
3. Metode Newton Raphson .....	63
4. Menunjukkan $\Delta = \left\{ \left( \frac{\partial^2 I(\xi)}{\partial a_j^2} \right) \left( \frac{\partial^2 I(\xi)}{\partial b_j^2} \right) - \left( \frac{\partial^2 I(\xi)}{\partial a_j \partial b_j} \right)^2 \right\} > 0$ dan $\left( \frac{\partial^2 I(\xi)}{\partial a_j^2} \right) < 0$ atau $\left( \frac{\partial^2 I(\xi)}{\partial b_j^2} \right) < 0$ .....	67
5. Data jawaban tes Matematika siswa kelas VII SMP XYZ .....	69



## **BAB I**

### **PENDAHULUAN**

#### **1.1 Latar Belakang**

*Item Response Model* adalah model yang digunakan untuk menganalisa apakah suatu soal dalam suatu alat tes baik atau tidak. Baik tidaknya suatu soal ditentukan oleh karakteristik soal yaitu tingkat kesulitan soal dan tingkat diskriminasi soal. Item Response Model diaplikasikan terutama untuk tes dengan format jawaban dikotomus atau benar-salah yang dapat dikodekan 1 dan 0.

Tingkat kesulitan soal menyatakan seberapa sulit soal tersebut. Tingkat diskriminasi soal merupakan kemampuan soal dalam membedakan peserta dengan berbagai tingkat kemampuan. Tingkat kesulitan soal dan tingkat diskriminasi soal menentukan probabilitas peserta tes menjawab benar suatu soal.

Untuk tingkat kesulitan soal, jika soal terlalu sulit maka probabilitas menjawab soal dengan benar akan kecil. Sebaliknya, jika soal terlalu mudah maka probabilitas menjawab soal dengan benar akan besar. Soal yang baik adalah soal yang menghasilkan probabilitas menjawab soal dengan benar mendekati 0,5.

Untuk tingkat diskriminasi soal, jika tingkat diskriminasi soal tinggi maka probabilitas jawaban benar untuk peserta dengan kemampuan rendah akan jauh lebih rendah dibandingkan dengan peserta dengan kemampuan tinggi. Sebaliknya, jika tingkat diskriminasi soal rendah maka probabilitas jawaban benar untuk peserta dengan kemampuan rendah dan peserta dengan kemampuan tinggi tidak terlalu berbeda. Soal yang baik adalah soal yang mempunyai tingkat diskriminasi tinggi.

Selain karakteristik soal, yaitu tingkat kesulitan soal dan tingkat diskriminasi soal, probabilitas menjawab benar suatu soal juga dipengaruhi oleh tingkat kemampuan peserta tes. *Item Response Model* memodelkan probabilitas peserta menjawab benar suatu soal sebagai fungsi dari kemampuan peserta tes dan karakteristik soal pada tes.

Misalkan,  $y =$  jawaban peserta tes

$$y = \begin{cases} 1, & \text{jika jawaban benar} \\ 0, & \text{jika jawaban salah} \end{cases}$$

$\theta =$  tingkat kemampuan peserta tes

$a =$  tingkat diskriminasi soal

$b =$  tingkat kesulitan soal

*Item Response Model* dapat ditulis dalam bentuk :

$$P(y=1) = F(\theta, a, b)$$

Dapat dimengerti bahwa semakin tinggi kemampuan yang dimiliki peserta tes maka probabilitas peserta tersebut menjawab soal dengan benar

akan semakin besar. Maka  $F(\theta, a, b)$  dapat diasumsikan sebagai fungsi monoton tidak turun. Dalam *item response model*,  $F(\theta, a, b)$  diasumsikan sebagai fungsi distribusi dari suatu distribusi.

Untuk tes yang terdiri dari sejumlah k soal dan diikuti sebanyak n peserta tes, *Item Response Model* dapat ditulis dalam bentuk :

$$P(y_{ij} = 1) = F(\theta_i, a_j, b_j), i=1, \dots, n; j=1, \dots, k$$

dengan

$y_{ij}$  = jawaban peserta tes ke-i untuk soal ke-j

$\theta_i$  = tingkat kemampuan peserta tes ke-i

$a_j$  = tingkat diskriminasi soal ke-j

$b_j$  = tingkat kesulitan soal ke-j

Jika nilai  $\theta_i$ ,  $a_j$ , dan  $b_j$ ;  $i=1, \dots, n$   $j=1, \dots, k$  dapat ditaksir sehingga dapat dianalisis apakah soal ke-j baik atau tidak.

Dalam skripsi ini akan dijelaskan cara mencari taksiran dari parameter tingkat kemampuan peserta, tingkat diskriminasi soal, dan tingkat kesulitan soal pada suatu alat tes yang terdiri dari k soal dan diikuti n peserta tes. Kemudian dari taksiran yang didapat akan dilakukan seleksi soal dengan cara membandingkan tingkat kebaikan soal-soal dalam alat tes tersebut.

## 1.2 Perumusan Masalah

1. Bagaimana mencari taksiran dari parameter tingkat kemampuan peserta tes, tingkat diskriminasi soal dan tingkat kesulitan soal.
2. Bagaimana mencari dan membandingkan tingkat kebaikan suatu soal terhadap tingkat kebaikan soal yang lain dalam suatu alat tes berdasarkan taksiran parameter yang didapat.

## 1.3 Tujuan

1. Mencari taksiran dari parameter tingkat kemampuan peserta tes, tingkat diskriminasi soal dan tingkat kesulitan soal.
2. Mencari tingkat kebaikan setiap soal dan membandingkannya dengan tingkat kebaikan soal yang lain berdasarkan taksiran parameter diatas.

## 1.4 Pembatasan Masalah

1.  $F(\theta_i, a_j, b_j)$  suatu *cumulative distribution function* (cdf) dari distribusi logistik standar.
2. Taksiran parameter  $\theta_i$ ,  $a_j$ , dan  $b_j$  dicari dengan *joint maximum likelihood estimation* (JMLE).

## **1.5 Aplikasi**

Item Response Model akan diterapkan untuk mengevaluasi soal-soal ulangan Matematika semester genap tahun 2007-2008 yang diberikan untuk siswa kelas VII SMP XYZ di kota A.

## **1.6 SISTEMATIKA PENULISAN**

Penulisan skripsi ini dibagi menjadi lima bab, yaitu :

### **BAB I PENDAHULUAN**

Bab ini menjelaskan secara singkat mengenai latar belakang, permasalahan, tujuan, pembatasan masalah, aplikasi dan sistematika penulisan.

### **BAB II LANDASAN TEORI**

Bab ini membahas landasan teori dari skripsi ini yaitu metode penaksiran *Maximum Likelihood*, metode penaksiran *Joint Maximum Likelihood*, dan *Fisher Information*.

### **BAB III ITEM RESPONSE MODEL**

Bab ini menjelaskan mengenai mencari taksiran dari parameter tingkat kemampuan peserta, tingkat diskriminasi soal dan tingkat kesulitan soal dari suatu alat tes yang terdiri dari k soal dan diberikan kepada n peserta tes dengan metode penaksiran *Joint Maximum Likelihood*. Kemudian mencari tingkat kebaikan setiap

soal dan membandingkannya dengan tingkat kebaikan soal yang lain dengan berdasarkan hasil taksiran yang didapat.

#### BAB IV APLIKASI

Bab ini menjelaskan aplikasi dari skripsi ini.

#### BAB V PENUTUP

Bab ini menampilkan kesimpulan dan saran.



## BAB II

### LANDASAN TEORI

Pada bab ini akan dibahas dasar-dasar teori yang akan digunakan dalam penulisan skripsi ini, yaitu mengenai metode penaksiran *maximum likelihood*, metode penaksiran *joint maximum likelihood* dan *fisher information*.

#### 2.1 Penaksiran *Maximum Likelihood*

Misal  $X_1, X_2, \dots, X_n$  adalah peubah acak yang iid dengan pdf  $f(x; \theta)$ ,  $\theta \in \Omega$  dimana  $\theta$  merupakan suatu parameter yang tidak diketahui dan  $\Omega$  adalah ruang parameter. Dalam melakukan penaksiran *maximum likelihood* ada beberapa tahapan yang harus dilakukan.

Pertama, cari pdf bersama dari  $X_1, X_2, \dots, X_n$  yaitu  $f(x_1, x_2, \dots, x_n; \theta)$ .

Karena  $X_1, X_2, \dots, X_n$  adalah peubah acak yang iid maka

$$f(x_1, x_2, \dots, x_n; \theta) = f(x_1; \theta)f(x_2; \theta)\dots f(x_n; \theta)$$

Kedua, cari fungsi *likelihoodnya*. Fungsi *likelihood* didefinisikan sebagai pdf bersama dari  $X_1, X_2, \dots, X_n$  yang dapat dianggap sebagai fungsi dari  $\theta$ . Misalkan fungsi *likelihood*  $L(\theta; x_1, x_2, \dots, x_n) = L(\theta)$

$$L(\theta) = f(x_1, x_2, \dots, x_n; \theta) = f(x_1; \theta)f(x_2; \theta)\dots f(x_n; \theta), \theta \in \Omega$$

$$= \prod_{i=1}^n f(x_i; \theta)$$

Ketiga, cari taksiran dari  $\theta$ . Dalam metode penaksiran *maximum likelihood* taksiran dari  $\theta$  diperoleh dengan menemukan nilai  $\theta$ , sebut  $\hat{\theta}$ , yang memaksimumkan fungsi *likelihood*. Maka  $\hat{\theta}$  disebut taksiran *maximum likelihood (maximum likelihood estimator / MLE)* dari  $\theta$ .

Mencari nilai  $\theta$  yang memaksimumkan fungsi  $\ln L(\theta)$ , sebut  $I(\theta)$ , akan memberikan hasil yang sama dengan mencari nilai  $\theta$  yang memaksimumkan  $L(\theta)$ . Maka baik  $L(\theta)$  atau  $I(\theta)$  dapat digunakan untuk mencari nilai  $\hat{\theta}$ . Bukti diberikan di lampiran1.

Nilai  $\theta$  yang memaksimumkan  $I(\theta)$  dapat diperoleh dengan mencari solusi dari persamaan

$$S(\theta) = \frac{\partial I(\theta)}{\partial \theta} = \frac{\partial \ln L(\theta)}{\partial \theta} = \frac{1}{L(\theta)} \cdot \frac{\partial L(\theta)}{\partial \theta} = 0.$$

## 2.2 Penaksiran *Joint Maximum Likelihood*

Misal  $X_1, X_2, \dots, X_n$  adalah peubah acak yang iid dengan pdf  $f(x; \theta)$ ,  $\theta \in \Omega \subset \mathbb{R}^p$  dimana  $\theta$  merupakan suatu vektor dari p-parameter yang tidak

diketahui. Dalam melakukan penaksiran *joint maximum likelihood* ada beberapa tahapan yang harus dilakukan.

Pertama, cari pdf bersama dari  $X_1, X_2, \dots, X_n$  yaitu  $f(x_1, x_2, \dots, x_n; \theta)$ .

Karena  $X_1, X_2, \dots, X_n$  adalah peubah acak yang iid maka

$$f(x_1, x_2, \dots, x_n; \theta) = f(x_1; \theta)f(x_2; \theta)\dots f(x_n; \theta).$$

Kedua, cari fungsi *likelihoodnya*. Fungsi *likelihood* didefinisikan sebagai pdf bersama dari  $X_1, X_2, \dots, X_n$  yang dapat dianggap sebagai fungsi dari  $\theta$ . Misalkan fungsi *likelihood*  $L(\theta; x_1, x_2, \dots, x_n) = L(\theta)$ .

$$L(\theta) = f(x_1, x_2, \dots, x_n; \theta) = f(x_1; \theta)f(x_2; \theta)\dots f(x_n; \theta), \theta \in \Omega$$

$$= \prod_{i=1}^n f(x_i; \theta)$$

Ketiga, cari taksiran dari  $\theta$ . Dalam metode penaksiran *joint maximum likelihood* taksiran dari  $\theta$  diperoleh dengan menemukan nilai  $\theta$ , sebut  $\hat{\theta}$ , yang memaksimumkan fungsi *likelihood*. Maka  $\hat{\theta}$  disebut taksiran *joint maximum likelihood* dari  $\theta$ .

Mencari nilai  $\theta$  yang memaksimumkan fungsi  $\ln L(\theta)$ , sebut  $I(\theta)$ , akan memberikan hasil yang sama dengan mencari nilai  $\theta$  yang memaksimumkan  $L(\theta)$ . Maka baik  $L(\theta)$  atau  $I(\theta)$  dapat digunakan untuk mencari nilai  $\hat{\theta}$ .

Bukti untuk  $\theta$  vektor dari n parameter,  $\theta = (\theta_1, \theta_2, \dots, \theta_n)$ , diberikan di lampiran2.

Nilai  $\theta$  yang memaksimumkan  $I(\theta)$  dapat diperoleh dengan mencari solusi simultan dari persamaan

$$S_j(\theta) = \frac{\partial}{\partial \theta_j} I(\theta), \text{ untuk } j=1,\dots,p$$

$$= \frac{\partial}{\partial \theta_j} \ln L(\theta)$$

$$= \frac{1}{L(\theta)} \cdot \frac{\partial}{\partial \theta_j} L(\theta) = 0.$$

Adakalanya sistem persamaan ini dapat diselesaikan secara analitik. Jika tidak, suatu prosedur numerik (misal teknik Newton-Raphson) dapat digunakan.

### 2.3 *Fisher Information*

Misalkan  $X$  adalah variabel random dengan pdf  $f(x; \theta)$ ,  $\theta \in \Omega$ , dimana ruang parameter  $\Omega$  adalah suatu interval, diasumsikan bahwa:

- $f(x; \theta)$  adalah positif pada himpunan  $S$  independen dari  $\theta \in \Omega$ .
- $\frac{\partial}{\partial \theta} f(x; \theta)$  ada  $\forall \theta \in \Omega$ , kecuali pada titik-titik dimana probabilitas = 0.
- $\int_S \dots \int_S f(x_1; \theta) \dots f(x_n; \theta) dx_1 \dots dx_n$  atau  $\sum_s \dots \sum_s f(x_1; \theta) \dots f(x_n; \theta)$  dapat dideferensiasi dibawah simbol integral atau sumasi.

Dengan asumsi diatas maka didapat (diberikan untuk kasus  $X$  variable random kontinu, untuk kasus diskrit dapat dijalankan similar) bahwa

$$\int_{-\infty}^{\infty} f(x; \theta) dx = 1$$

dengan mengambil turunan pertama terhadap  $\theta$  didapat,

misalkan  $g(\theta) = \int_{-\infty}^{\infty} f(x; \theta) dx$  maka  $\frac{d}{d\theta} g(\theta) = 0$  atau dapat ditulis

$$\begin{aligned}\frac{d}{d\theta} g(\theta) &= \lim_{h \rightarrow 0} \frac{g(\theta + h) - g(\theta)}{h} \\ &= \lim_{h \rightarrow 0} \frac{\int_{-\infty}^{\infty} f(x; \theta + h) dx - \int_{-\infty}^{\infty} f(x; \theta) dx}{h} \\ &= \lim_{h \rightarrow 0} \frac{\int_{-\infty}^{\infty} [f(x; \theta + h) - f(x; \theta)] dx}{h} \\ &= \lim_{h \rightarrow 0} \int_{-\infty}^{\infty} \frac{f(x; \theta + h) - f(x; \theta)}{h} dx \\ \frac{d}{d\theta} g(\theta) &= \int_{-\infty}^{\infty} \frac{\partial f(x; \theta)}{\partial \theta} dx\end{aligned}$$

Maka dapat ditulis,

$$\int_{-\infty}^{\infty} \frac{\partial f(x; \theta)}{\partial \theta} dx = 0. \quad (1)$$

Persamaan (1) dapat ditulis sebagai

$$\int_{-\infty}^{\infty} \frac{\frac{\partial f(x; \theta)}{\partial \theta}}{f(x; \theta)} \cdot f(x; \theta) dx = 0$$

atau sama dengan

$$\int_{-\infty}^{\infty} \frac{\partial \ln f(x; \theta)}{\partial \theta} \cdot f(x; \theta) dx = 0. \quad (2)$$

Jika diturunkan kembali terhadap  $\theta$  didapat,

$$\int_{-\infty}^{\infty} \left[ \frac{\partial^2 \ln f(x; \theta)}{\partial \theta^2} \cdot f(x; \theta) + \frac{\partial \ln f(x; \theta)}{\partial \theta} \cdot \frac{\partial f(x; \theta)}{\partial \theta} \right] dx = 0. \quad (3)$$

Bentuk kedua dari persamaan (3) disebelah kiri dapat ditulis sebagai

$$\int_{-\infty}^{\infty} \frac{\partial \ln f(x; \theta)}{\partial \theta} \cdot \frac{\partial f(x; \theta)}{\partial \theta} \cdot f(x; \theta) dx = \int_{-\infty}^{\infty} \frac{\partial \ln f(x; \theta)}{\partial \theta} \cdot \frac{\partial \ln f(x; \theta)}{\partial \theta} \cdot f(x; \theta) dx$$

atau

$$\int_{-\infty}^{\infty} \frac{\partial \ln f(x; \theta)}{\partial \theta} \cdot \frac{\partial f(x; \theta)}{\partial \theta} \cdot f(x; \theta) dx = \int_{-\infty}^{\infty} \left[ \frac{\partial \ln f(x; \theta)}{\partial \theta} \right]^2 \cdot f(x; \theta) dx$$

Bentuk diatas disebut *Fisher Information*, dinotasikan dengan  $I(\theta)$ . Yaitu,

$$I(\theta) = \int_{-\infty}^{\infty} \left[ \frac{\partial \ln f(x; \theta)}{\partial \theta} \right]^2 \cdot f(x; \theta) dx$$

Dari persamaan (3),  $I(\theta)$  juga dapat ditulis dalam bentuk

$$I(\theta) = - \int_{-\infty}^{\infty} \frac{\partial^2 \ln f(x; \theta)}{\partial \theta^2} \cdot f(x; \theta) dx$$

Catatan : informasi yang dimaksud adalah mean terboboti dari  $\left[ \frac{\partial \ln f(x; \theta)}{\partial \theta} \right]^2$

atau  $\left[ -\frac{\partial^2 \ln f(x; \theta)}{\partial \theta^2} \right]$ , dimana bobot diberikan oleh pdf  $f(x; \theta)$ . *Fisher*

*Information* juga dapat diberikan dalam bentuk  $E\left(\left[\frac{\partial \ln f(x; \theta)}{\partial \theta}\right]^2\right)$ . Hal ini

diperoleh dari bentuk

$$I(\theta) = E\left(\left[\frac{\partial \ln f(x; \theta)}{\partial \theta}\right]^2\right) = \int_{-\infty}^{\infty} \left[\frac{\partial \ln f(x; \theta)}{\partial \theta}\right]^2 \cdot f(x; \theta) dx. \text{ Karena p.d.f}$$

merupakan fungsi nonnegatif atau dengan kata lain  $f(x; \theta) \geq 0$  dan tentu saja

$\left[\frac{\partial \ln f(x; \theta)}{\partial \theta}\right]^2 \geq 0$  maka semakin besar nilai turunan  $\frac{\partial \ln f(x; \theta)}{\partial \theta}$ , semakin

besar nilai ekspektasinya. Jadi semakin banyak informasi yang diperoleh.

Jelas bahwa, jika  $\left[\frac{\partial \ln f(x; \theta)}{\partial \theta}\right]^2 = 0$  maka  $\frac{\partial \ln f(x; \theta)}{\partial \theta} = 0$  dengan kata lain

$\ln f(x; \theta)$  merupakan suatu fungsi yang tidak mengandung  $\theta$ . Maka tidak terdapat informasi tentang  $\theta$  atau dengan kata lain terdapat nol informasi tentang  $\theta$ .

## **BAB III**

### ***ITEM RESPONSE MODEL***

#### **3.1 Pengantar**

Dalam penelitian di beberapa bidang studi seperti bidang psikologi dan bidang pendidikan, peneliti biasanya tertarik untuk mengukur kemampuan seorang individu seperti intelegensi, kemampuan matematika, atau kemampuan skolastik. Namun, kuantitas kemampuan seorang individu tidak dapat diukur secara langsung layaknya mengukur atribut fisik seperti berat atau tinggi badan.

Pengukuran dilakukan dengan menggunakan kuisioner atau tes. Untuk itu soal didalam tes harus dapat secara efektif dan akurat mengukur kemampuan peserta tes. Untuk menganalisa baik atau tidaknya suatu soal dalam suatu alat tes dalam mengukur kemampuan para peserta tes digunakan suatu metode yang dikenal dengan *Item Response Model* (IRM).

## **3.2 Konsep Dasar IRM**

### **3.2.1 *Latent Ability***

Performa seorang peserta tes dalam menjawab suatu soal dipengaruhi oleh *latent ability* yang dimiliki peserta tes. *Latent ability* peserta tes merupakan kemampuan peserta tes yang tidak dapat diukur secara langsung. Dalam literatur mengenai *IRM*, *latent ability* dinotasikan dengan  $\theta$ . Dalam aplikasinya, *latent ability* merupakan pengetahuan yang dimiliki peserta tes terhadap soal yang ditanyakan. *Latent ability* diasumsikan kontinu dan berdimensi satu. Namun untuk tujuan praktis, nilai  $\theta$  distandarisasi dengan jangkauan dibatasi antara -3 sampai 3. Karena distandarisasi maka  $\theta$  mempunyai mean 0 dan standar deviasi 1. Nilai mean nol menyatakan rata-rata kemampuan yang dimiliki peserta dalam tes tersebut. Semakin besar  $\theta$ , yaitu nilai  $\theta>0$ , semakin tinggi kemampuan peserta tes. Semakin kecil  $\theta$ , yaitu nilai  $\theta<0$ , semakin rendah kemampuan peserta tes.

### **3.2.2 Karakteristik Soal**

Soal-soal dalam tes memiliki dua karakteristik yaitu tingkat diskriminasi soal dan tingkat kesulitan soal. Tingkat diskriminasi soal, dinotasikan dengan  $a$ , merupakan kemampuan soal dalam membedakan peserta dengan

berbagai tingkat kemampuan. Sedangkan tingkat kesulitan soal, dinotasikan dengan  $b$ , menyatakan seberapa sulit soal tersebut.

### 3.2.3 Item Response Curve

Misalkan  $y$  adalah jawaban peserta tes atas suatu soal,  $y = 1$  jika jawaban benar dan  $y = 0$  jika jawaban salah. Diasumsikan probabilitas peserta menjawab benar suatu soal hanya dipengaruhi oleh kemampuan peserta ( $\theta$ ) dan karakteristik soal ( $a,b$ ). Jika  $p$  adalah probabilitas jawaban benar, maka dapat dimodelkan

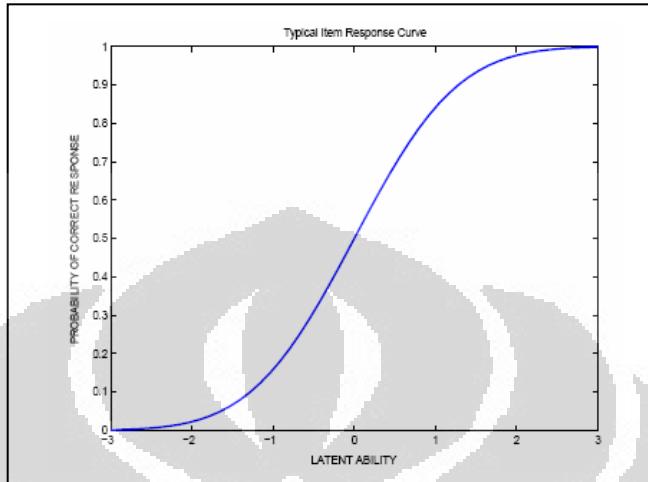
$$p = \Pr(Y = 1) = F(\theta, a, b)$$

dengan  $F$  adalah suatu fungsi dari kemampuan peserta tes dan karakteristik soal.

Dapat dimengerti bahwa probabilitas peserta menjawab soal dengan benar akan semakin besar jika kemampuan peserta semakin tinggi. Maka  $F(\theta, a, b)$  dapat diasumsikan sebagai fungsi monoton tidak turun.  $F(\theta, a, b)$  biasanya diasumsikan sebagai fungsi distribusi.

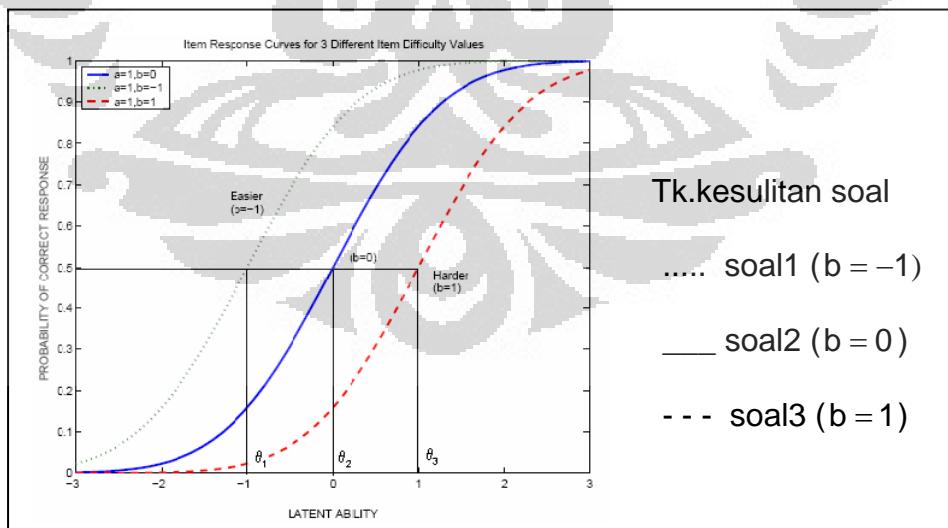
Memplot probabilitas peserta menjawab benar suatu soal atas kemampuan peserta tes akan menghasilkan plot seperti Gambar 1. Kurva ini disebut kurva item response (Item Response Curve / IRC). Bentuk Item Response Curve (IRC) menggambarkan bagaimana perubahan tingkat

kemampuan mengakibatkan perubahan dalam probabilitas menjawab benar suatu soal.



Gambar 1. Item response curve

Untuk melihat efek tingkat kesulitan soal dalam IRC akan ditunjukkan, dalam Gambar 2, plot IRC dari tiga soal berbeda dengan nilai parameter tingkat diskriminasi soal , a, yang sama dan tingkat kesulitan soal, b, yang berbeda.



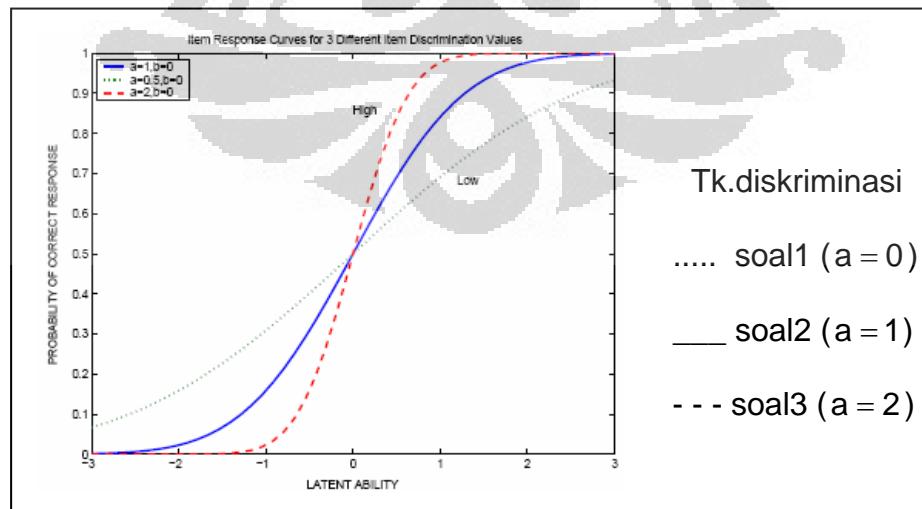
Gambar 2. Item response curve dari tiga soal

dengan tingkat kesulitan berbeda

Beberapa ciri dari IRC tersebut dapat diamati. Pertama, setiap IRC memiliki bentuk-S atau S-shaped, yang mana probabilitas jawaban benar digambar sebagai fungsi monoton tidak turun dari *latent ability*. Kedua, walaupun tiga IRC diatas memiliki bentuk yang sama, namun berbeda lokasinya. Pada Gambar 2, lokasi IRC merujuk pada parameter tingkat kesulitan soal. Nilai parameter tingkat kesulitan soal,  $b$ , didefinisikan sebagai nilai  $\theta$  saat  $p = 0,5$ .

Dari Gambar 2 diatas, probabilitas menjawab benar sama dengan 0,5 untuk soal 1 dicapai oleh peserta tes dengan *latent ability*  $\theta_1$  yang lebih kecil dari  $\theta_2$  dan  $\theta_3$ . Jadi dapat disimpulkan bahwa soal1 lebih mudah dibandingkan soal2 dan soal3.

Untuk melihat efek tingkat diskriminasi soal dalam IRC akan ditunjukkan, dalam Gambar 3, plot IRC dari tiga soal berbeda dengan nilai parameter tingkat diskriminasi soal,  $a$ , yang berbeda dan tingkat kesulitan soal,  $b$ , yang sama.



### Gambar 3 Item response curve dari tiga soal

dengan tingkat diskriminasi berbeda

Tiga soal dalam Gambar 3 memiliki slope yang berbeda. Slope menyatakan tingkat diskriminasi soal. Slope menggambarkan seberapa cepat perubahan probabilitas menjawab benar terhadap *latent ability*nya. Soal1 memiliki perubahan probabilitas menjawab benar terhadap *latent ability* yang lebih lambat dibanding dengan soal2 dan soal3. Maka soal1 kurang mendiskriminasi dibanding soal2 dan soal3.

Parameter tingkat diskriminasi soal memiliki nilai lebih besar nol (yaitu  $a > 0$ ), artinya dengan tingkat kesulitan, b, yang sama maka peserta dengan *latent ability*,  $\theta$ , yang lebih tinggi akan memiliki probabilitas menjawab benar suatu soal lebih besar dari peserta lainnya.

## 3.3 Item Response Model Untuk Sejumlah Peserta Tes

### 3.3.1 Struktur Data

Misalkan terdapat n-peserta yang mengikuti suatu tes dengan k-soal. Tiap soal memiliki format jawaban dikotomus yang dapat dikodekan 1 atau 0. Maka data hasil tes dapat ditulis dalam bentuk matriks  $n \times k$  dengan entri 1 dan 0. Baris pertama dari matriks menunjukkan jawaban-jawaban dari peserta pertama, baris kedua menunjukkan jawaban-jawaban dari peserta

kedua, dan seterusnya. Serupa dengan hal tersebut, kolom pertama matriks menunjukkan jawaban-jawaban peserta tes untuk soal pertama, kolom kedua menunjukkan jawaban-jawaban peserta tes untuk soal kedua, dan seterusnya.

Misalkan  $y_{ij}$  adalah jawaban peserta tes ke-i untuk soal tes ke-j, maka data hasil tes dapat diberikan dalam bentuk sebagai berikut

$$\begin{array}{c} \text{peserta 1} \\ \text{peserta 2} \\ \vdots \\ \text{peserta n} \end{array} \left( \begin{array}{cccc} \text{soal 1} & \text{soal 2} & \cdots & \text{soal k} \\ y_{11} & y_{12} & \cdots & y_{1k} \\ y_{21} & y_{22} & \cdots & y_{2k} \\ \vdots & \vdots & \ddots & \vdots \\ y_{n1} & y_{n2} & \cdots & y_{nk} \end{array} \right)$$

### 3.3.2 Asumsi Model

Seperti telah dijelaskan sebelumnya, performa peserta tes ke-i dalam menjawab soal dipengaruhi oleh *latent ability* yang dimilikinya,  $\theta_i$ ,  $i = 1, \dots, n$ .

Karena probabilitas seorang individu menjawab soal dengan benar diasumsikan hanya dipengaruhi oleh *latent ability* yang dimilikinya dan karakteristik soal pada tes, maka model probabilitas jawaban benar untuk peserta ke-i dan soal ke-j dapat didefinisikan sebagai berikut

$$\Pr(Y_{ij} = 1 ; \theta_i, a_j, b_j) = F(a_j\theta_i - b_j) \quad (3.1)$$

dengan  $-\infty < \theta_i < \infty$ ,  $0 < a_j < \infty$ , dan  $-\infty < b_j < \infty$ .

Seperti sebelumnya,  $F(a_j\theta_i - b_j)$  menyatakan suatu fungsi distribusi yang diketahui dan  $a_j$  dan  $b_j$  adalah parameter diskriminasi soal dan kesulitan soal ke- $j$ . Dalam skripsi ini,  $F(a_j\theta_i - b_j)$  diasumsikan suatu fungsi distribusi dari distribusi logistik standar. Berdasarkan distribusi Bernoulli, maka probabilitas jawaban  $y_{ij}$  dapat dituliskan sebagai berikut

$$\Pr(Y_{ij} = y_{ij} ; \theta_i, a_j, b_j) = F(a_j\theta_i - b_j)^{y_{ij}} [1 - F(a_j\theta_i - b_j)]^{1-y_{ij}} \quad (3.2)$$

dengan  $y_{ij} = 0$  atau  $1$ .

Probabilitas yang diberikan dalam (3.1) menyatakan probabilitas seorang peserta tes menjawab dengan benar satu soal tes. Untuk menggabungkan jawaban seorang peserta terhadap keseluruhan soal, diperlukan suatu asumsi yaitu *local independence*. Sifat *local independence* pada IRM dapat diartikan sebagai kebebasan (*independent*) jawaban antar soal. Dalam kaitannya pada IRM, hal tersebut memiliki arti bahwa jawaban yang diberikan setiap peserta tes untuk suatu soal independen terhadap jawaban yang diberikannya untuk soal lainnya.

### 3.4 Estimasi Parameter *Latent ability* dan Karakteristik Soal

#### 3.4.1 Fungsi *Likelihood*

Misalkan  $y_{i1}, y_{i2}, \dots, y_{ik}$  menyatakan jawaban biner dari peserta ke-i dengan *latent ability*  $\theta_i$  untuk k soal, dan  $\mathbf{a} = (a_1, \dots, a_k)$  dan  $\mathbf{b} = (b_1, \dots, b_k)$  merupakan vektor dari parameter tingkat diskriminasi soal dan tingkat kesulitan soal. Dengan asumsi *local independence*, maka probabilitas peserta tes ke-i menjawab seluruh k-soal dalam tes dapat ditulis dalam bentuk

$$\begin{aligned}\Pr(Y_{i1} = y_{i1}, \dots, Y_{ik} = y_{ik} ; \theta_i, \mathbf{a}, \mathbf{b}) &= \Pr(Y_{i1} = y_{i1} ; \theta_i, a_1, b_1) \times \dots \times \Pr(Y_{ik} = y_{ik} ; \theta_i, a_k, b_k) \\ &= \prod_{j=1}^k \Pr(Y_{ij} = y_{ij} ; \theta_i, a_j, b_j) \\ &= \prod_{j=1}^k F(a_j \theta_i - b_j)^{y_{ij}} [1 - F(a_j \theta_i - b_j)]^{1-y_{ij}}\end{aligned}$$

Untuk menggabungkan jawaban dari seluruh peserta tes, diasumsikan bahwa jawaban antar peserta tes terhadap soal saling independen. Fungsi *likelihood* diperoleh sebagai hasil kali probabilitas jawaban dari seluruh n-peserta tes atas seluruh k-soal dalam tes, atau dapat ditulis

$$\begin{aligned}L(\boldsymbol{\theta}, \mathbf{a}, \mathbf{b}) &= L(\boldsymbol{\theta}, \mathbf{a}, \mathbf{b} ; Y_{11} = y_{11}, \dots, Y_{nk} = y_{nk}) \\ &= \Pr(Y_{11} = y_{11}, \dots, Y_{nk} = y_{nk} ; \boldsymbol{\theta}, \mathbf{a}, \mathbf{b})\end{aligned}$$

$$\begin{aligned}
&= \Pr(Y_{11} = y_{11}, \dots, Y_{1k} = y_{1k} ; \theta_1, \mathbf{a}, \mathbf{b}) \times \dots \times \Pr(Y_{n1} = y_{n1}, \dots, Y_{nk} = y_{nk} ; \theta_n, \mathbf{a}, \mathbf{b}) \\
&= \prod_{i=1}^n \Pr(Y_{i1} = y_{i1}, \dots, Y_{ik} = y_{ik} ; \theta_i, \mathbf{a}, \mathbf{b}) \\
&= \prod_{i=1}^n \left[ \prod_{j=1}^k \Pr(Y_{ij} = y_{ij} ; \theta_i, \mathbf{a}_j, \mathbf{b}_j) \right] \\
L(\boldsymbol{\theta}, \mathbf{a}, \mathbf{b}) &= \prod_{i=1}^n \prod_{j=1}^k F(a_j \theta_i - b_j)^{y_{ij}} [1 - F(a_j \theta_i - b_j)]^{1-y_{ij}}
\end{aligned} \tag{3.3}$$

Taksiran parameter dalam model didapat dengan mencari nilai parameter yang memaksimumkan fungsi *likelihood* tersebut. Untuk itu diperlukan suatu metode penaksiran. Dalam skripsi ini metode penaksiran yang digunakan adalah metode penaksiran *Joint Maximum Likelihood (Joint Maximum Likelihood Estimation / JMLE)*.

### 3.4.2 Joint Maximum Likelihood Estimation

Prinsip dari metode ini adalah mencari taksiran parameter  $\theta_i$  ( $i=1, \dots, n$ ),  $a_j$ , dan  $b_j$  ( $j=1, \dots, k$ ) yang secara bersama memaksimumkan fungsi *likelihood*.

Mencari nilai taksiran vektor parameter  $(\boldsymbol{\theta}, \mathbf{a}, \mathbf{b})$ , sebut  $(\hat{\boldsymbol{\theta}}, \hat{\mathbf{a}}, \hat{\mathbf{b}})$ , yang memaksimumkan bentuk logaritma dari fungsi *likelihood*,  $\ln L(\boldsymbol{\theta}, \mathbf{a}, \mathbf{b})$ , sebut

$I(\theta, \mathbf{a}, \mathbf{b})$ , akan memberikan hasil yang sama dengan mencari nilai  $(\hat{\theta}, \hat{\mathbf{a}}, \hat{\mathbf{b}})$

yang memaksimumkan fungsi *likelihood*,  $L(\theta, \mathbf{a}, \mathbf{b})$ . Maka baik  $L(\theta, \mathbf{a}, \mathbf{b})$  atau

$I(\theta, \mathbf{a}, \mathbf{b})$  dapat digunakan untuk mencari nilai  $(\hat{\theta}, \hat{\mathbf{a}}, \hat{\mathbf{b}})$ .

$$I(\theta, \mathbf{a}, \mathbf{b}) = \ln L(\theta, \mathbf{a}, \mathbf{b})$$

$$= \ln \left[ \prod_{i=1}^n \prod_{j=1}^k F(a_j \theta_i - b_j)^{y_{ij}} [1 - F(a_j \theta_i - b_j)]^{1-y_{ij}} \right]$$

$$= \ln \left[ \prod_{i=1}^n \prod_{j=1}^k p_{ij}^{y_{ij}} [1 - p_{ij}]^{1-y_{ij}} \right], \text{ dengan } p_{ij} = F(a_j \theta_i - b_j)$$

$$\begin{aligned} &= \ln \left[ p_{11}^{y_{11}} (1-p_{11})^{1-y_{11}} \times \dots \times p_{1k}^{y_{1k}} (1-p_{1k})^{1-y_{1k}} \times \right. \\ &\quad p_{21}^{y_{21}} (1-p_{21})^{1-y_{21}} \times \dots \times p_{2k}^{y_{2k}} (1-p_{2k})^{1-y_{2k}} \times \\ &\quad \dots \dots \dots \times \\ &\quad \left. p_{n1}^{y_{n1}} (1-p_{n1})^{1-y_{n1}} \times \dots \times p_{nk}^{y_{nk}} (1-p_{nk})^{1-y_{nk}} \right] \end{aligned}$$

$$= \ln \left[ (p_{11}^{y_{11}} \times \dots \times p_{nk}^{y_{nk}}) \cdot ((1-p_{11})^{1-y_{11}} \times \dots \times (1-p_{nk})^{1-y_{nk}}) \right]$$

$$= \ln \left[ p_{11}^{y_{11}} \times \dots \times p_{nk}^{y_{nk}} \right] + \ln \left[ (1-p_{11})^{1-y_{11}} \times \dots \times (1-p_{nk})^{1-y_{nk}} \right]$$

$$= [y_{11} \ln(p_{11}) + \dots + y_{nk} \ln(p_{nk})] + [(1-y_{11}) \ln(1-p_{11}) + \dots + (1-y_{nk}) \ln(1-p_{nk})]$$

$$= \{y_{11} \ln(p_{11}) + (1-y_{11}) \ln(1-p_{11})\} + \dots + \{y_{nk} \ln(p_{nk}) + (1-y_{nk}) \ln(1-p_{nk})\}$$

$$I(\theta, \mathbf{a}, \mathbf{b}) = \sum_{i=1}^n \sum_{j=1}^k \{y_{ij} \ln(p_{ij}) + (1-y_{ij}) \ln(1-p_{ij})\} \quad (3.4)$$

Secara langsung memaksimumkan fungsi *likelihood*  $L(\theta, \mathbf{a}, \mathbf{b})$  pada persamaan 3.3 cukup sulit karena merupakan suatu bentuk perkalian. Akan lebih mudah memaksimumkan  $l(\theta, \mathbf{a}, \mathbf{b})$  yang merupakan suatu bentuk penjumlahan. Hal ini dikarenakan lebih mudah menurunkan bentuk penjumlahan daripada menurunkan bentuk perkalian.

Telah diberikan diatas bahwa probabilitas jawaban benar untuk peserta ke- $i$  dan soal ke- $j$  didefinisikan sebagai

$$p_{ij} = \Pr(Y_{ij} = 1; \theta_i, a_j, b_j) = F(a_j\theta_i - b_j)$$

dimana,  $F(a_j\theta_i - b_j)$  diasumsikan suatu fungsi distribusi dari distribusi logistik standar. Maka dapat ditulis

$$p_{ij} = \left( \frac{e^{a_j\theta_i - b_j}}{1 + e^{a_j\theta_i - b_j}} \right) = \left( \frac{1}{1 + e^{-(a_j\theta_i - b_j)}} \right) = \left( 1 + e^{-(a_j\theta_i - b_j)} \right)^{-1}$$

dan probabilitas jawaban salah untuk peserta ke- $i$  dan soal ke- $j$ , dinotasikan dengan  $q_{ij}$ , diberikan sebagai berikut

$$q_{ij} = 1 - p_{ij} = \left( 1 - \frac{e^{a_j\theta_i - b_j}}{1 + e^{a_j\theta_i - b_j}} \right) = \left( \frac{1}{1 + e^{a_j\theta_i - b_j}} \right).$$

Turunan parsial pertama  $p_{ij}$  terhadap parameter  $a_j$ ,  $b_j$ , dan  $\theta_i$  adalah

$$\frac{\partial p_{ij}}{\partial a_j} = -1 \cdot \left( 1 + e^{-(a_j\theta_i - b_j)} \right)^{-2} \cdot (-\theta_i) \cdot \left( e^{-(a_j\theta_i - b_j)} \right)$$

$$= \theta_i \cdot \left( \frac{1}{1 + e^{-(a_j\theta_i - b_j)}} \right) \cdot \left( \frac{e^{-(a_j\theta_i - b_j)}}{1 + e^{-(a_j\theta_i - b_j)}} \right)$$

$$= \theta_i \cdot \left( \frac{1}{1+e^{-(a_j\theta_i-b_j)}} \right) \cdot \left( \frac{1}{1+e^{a_j\theta_i-b_j}} \right)$$

$$\frac{\partial p_{ij}}{\partial a_j} = \theta_i \cdot p_{ij} \cdot q_{ij} \quad (3.5)$$

$$\begin{aligned} \frac{\partial p_{ij}}{\partial b_j} &= -1 \cdot \left( 1 + e^{-(a_j\theta_i-b_j)} \right)^{-2} \cdot \left( e^{-(a_j\theta_i-b_j)} \right) \\ &= -1 \cdot \left( \frac{1}{1+e^{-(a_j\theta_i-b_j)}} \right) \cdot \left( \frac{e^{-(a_j\theta_i-b_j)}}{1+e^{-(a_j\theta_i-b_j)}} \right) \\ \frac{\partial p_{ij}}{\partial b_j} &= -p_{ij} \cdot q_{ij} \end{aligned} \quad (3.6)$$

$$\begin{aligned} \frac{\partial p_{ij}}{\partial \theta_i} &= -1 \cdot \left( 1 + e^{-(a_j\theta_i-b_j)} \right)^{-2} \cdot (-a_j) \cdot \left( e^{-(a_j\theta_i-b_j)} \right) \\ &= a_j \cdot \left( \frac{1}{1+e^{-(a_j\theta_i-b_j)}} \right) \cdot \left( \frac{e^{-(a_j\theta_i-b_j)}}{1+e^{-(a_j\theta_i-b_j)}} \right) \\ &= a_j \cdot \left( \frac{1}{1+e^{-(a_j\theta_i-b_j)}} \right) \cdot \left( \frac{1}{1+e^{a_j\theta_i-b_j}} \right) \\ \frac{\partial p_{ij}}{\partial \theta_i} &= a_j \cdot p_{ij} \cdot q_{ij} \end{aligned} \quad (3.7)$$

Taksiran *Joint Maximum Likelihood* (JML) dari parameter  $\theta_i$ ,  $a_j$ , dan

$b_j$ , diperoleh dengan mendiferensiasi secara parsial fungsi  $I(\boldsymbol{\theta}, \mathbf{a}, \mathbf{b})$

terhadap parameter  $\theta_i$ ,  $a_j$ , dan  $b_j$  kemudian disamakan dengan nol. Langkah ini akan menghasilkan  $n+2k$  persamaan.

Dengan memakai persamaan (3.5), (3.6), dan (3.7) diatas, maka turunan parsial pertama dari  $I(\boldsymbol{\theta}, \mathbf{a}, \mathbf{b})$  terhadap  $\theta_i$ ,  $a_j$ , dan  $b_j$  adalah sebagai berikut:

$$\begin{aligned}
\frac{\partial I(\boldsymbol{\theta}, \mathbf{a}, \mathbf{b})}{\partial \theta_i} &= \frac{\partial}{\partial \theta_i} \sum_{j=1}^k \left\{ y_{ij} \ln(p_{ij}) + (1-y_{ij}) \ln(1-p_{ij}) \right\} , i = 1, \dots, n \\
&= \sum_{j=1}^k \frac{\partial}{\partial \theta_i} \left\{ y_{ij} \ln(p_{ij}) + (1-y_{ij}) \ln(1-p_{ij}) \right\} \\
&= \sum_{j=1}^k \left\{ \frac{y_{ij}}{p_{ij}} \cdot \frac{\partial p_{ij}}{\partial \theta_i} + \frac{(1-y_{ij})}{(1-p_{ij})} \cdot \frac{\partial (1-p_{ij})}{\partial \theta_i} \right\} \\
&= \sum_{j=1}^k \left\{ \frac{y_{ij}}{p_{ij}} \cdot (a_j \cdot p_{ij} \cdot q_{ij}) + \frac{(1-y_{ij})}{q_{ij}} \cdot -(a_j \cdot p_{ij} \cdot q_{ij}) \right\} \\
&= \sum_{j=1}^k \left\{ y_{ij} \cdot (a_j \cdot q_{ij}) + (1-y_{ij}) \cdot -(a_j \cdot p_{ij}) \right\} \\
&= \sum_{j=1}^k \left\{ y_{ij} \cdot a_j \cdot (1-p_{ij}) - a_j \cdot p_{ij} + y_{ij} \cdot a_j \cdot p_{ij} \right\} \\
&= \sum_{j=1}^k \left\{ y_{ij} \cdot a_j - a_j \cdot p_{ij} \right\} \\
&= \sum_{j=1}^k a_j \left\{ y_{ij} - p_{ij} \right\} \\
\frac{\partial I(\boldsymbol{\theta}, \mathbf{a}, \mathbf{b})}{\partial \theta_i} &= \sum_{j=1}^k a_j \left\{ y_{ij} - \left( \frac{e^{a_j \theta_i - b_j}}{1 + e^{a_j \theta_i - b_j}} \right) \right\} = 0 \quad , i = 1, \dots, n \tag{3.8}
\end{aligned}$$

$$\begin{aligned}
\frac{\partial I(\boldsymbol{\theta}, \mathbf{a}, \mathbf{b})}{\partial a_j} &= \frac{\partial}{\partial a_j} \sum_{i=1}^n \left\{ y_{ij} \ln(p_{ij}) + (1-y_{ij}) \ln(1-p_{ij}) \right\} , j = 1, \dots, k \\
&= \sum_{i=1}^n \frac{\partial}{\partial a_j} \left\{ y_{ij} \ln(p_{ij}) + (1-y_{ij}) \ln(1-p_{ij}) \right\} \\
&= \sum_{i=1}^n \left\{ \frac{y_{ij}}{p_{ij}} \cdot \frac{\partial p_{ij}}{\partial a_j} + \frac{(1-y_{ij})}{(1-p_{ij})} \cdot \frac{\partial (1-p_{ij})}{\partial a_j} \right\} \\
&= \sum_{i=1}^n \left\{ \frac{y_{ij}}{p_{ij}} \cdot (\theta_i \cdot p_{ij} \cdot q_{ij}) + \frac{(1-y_{ij})}{q_{ij}} \cdot -(\theta_i \cdot p_{ij} \cdot q_{ij}) \right\} \\
&= \sum_{i=1}^n \left\{ \frac{y_{ij}}{p_{ij}} \cdot (\theta_i \cdot p_{ij} \cdot q_{ij}) + \frac{(1-y_{ij})}{q_{ij}} \cdot -(\theta_i \cdot p_{ij} \cdot q_{ij}) \right\} \\
&= \sum_{i=1}^n \left\{ y_{ij} \cdot \theta_i \cdot q_{ij} - \theta_i \cdot p_{ij} + y_{ij} \cdot \theta_i \cdot p_{ij} \right\} \\
&= \sum_{i=1}^n \left\{ y_{ij} \cdot \theta_i \cdot (1-p_{ij}) - \theta_i \cdot p_{ij} + y_{ij} \cdot \theta_i \cdot p_{ij} \right\} \\
&= \sum_{i=1}^n \left\{ y_{ij} \cdot \theta_i - \theta_i \cdot p_{ij} \right\} \\
&= \sum_{i=1}^n \theta_i \left\{ y_{ij} - p_{ij} \right\} \\
\frac{\partial I(\boldsymbol{\theta}, \mathbf{a}, \mathbf{b})}{\partial a_j} &= \sum_{i=1}^n \theta_i \left\{ y_{ij} - \left( \frac{e^{a_j \theta_i - b_j}}{1 + e^{a_j \theta_i - b_j}} \right) \right\} = 0 , j = 1, \dots, k \quad (3.9)
\end{aligned}$$

dan

$$\frac{\partial I(\boldsymbol{\theta}, \mathbf{a}, \mathbf{b})}{\partial b_j} = \frac{\partial}{\partial b_j} \sum_{i=1}^n \left\{ y_{ij} \ln(p_{ij}) + (1-y_{ij}) \ln(1-p_{ij}) \right\} , j = 1, \dots, k$$

$$\begin{aligned}
&= \sum_{i=1}^n \frac{\partial}{\partial b_j} \left\{ y_{ij} \ln(p_{ij}) + (1-y_{ij}) \ln(1-p_{ij}) \right\} \\
&= \sum_{i=1}^n \left\{ \frac{y_{ij}}{p_{ij}} \cdot \frac{\partial p_{ij}}{\partial b_j} + \frac{(1-y_{ij})}{(1-p_{ij})} \cdot \frac{\partial (1-p_{ij})}{\partial b_j} \right\} \\
&= \sum_{i=1}^n \left\{ \frac{y_{ij}}{p_{ij}} \cdot (-p_{ij} \cdot q_{ij}) + \frac{(1-y_{ij})}{q_{ij}} \cdot -(-p_{ij} \cdot q_{ij}) \right\} \\
&= \sum_{i=1}^n \left\{ y_{ij} \cdot (-q_{ij}) + (1-y_{ij}) \cdot p_{ij} \right\} \\
&= \sum_{i=1}^n \left\{ y_{ij} \cdot (p_{ij} - 1) + (1-y_{ij}) \cdot p_{ij} \right\} \\
&= \sum_{i=1}^n \left\{ p_{ij} - y_{ij} \right\} \\
\frac{\partial l(\boldsymbol{\theta}, \mathbf{a}, \mathbf{b})}{\partial b_j} &= \sum_{i=1}^n \left\{ \left( \frac{e^{a_i \theta_i - b_j}}{1 + e^{a_i \theta_i - b_j}} \right) - y_{ij} \right\} = 0 \quad , j = 1, \dots, k \tag{3.10}
\end{aligned}$$

Persamaan (3.8), (3.9), dan (3.10) disebut persamaan *likelihoood*.

Ketiga persamaan *likelihoood* tersebut dapat dinyatakan dalam bentuk vektor, yaitu:

$$\begin{bmatrix} \frac{\partial l(\boldsymbol{\theta}, \boldsymbol{\xi})}{\partial \theta_i} \\ \frac{\partial l(\boldsymbol{\theta}, \boldsymbol{\xi})}{\partial a_j} \\ \frac{\partial l(\boldsymbol{\theta}, \boldsymbol{\xi})}{\partial b_j} \end{bmatrix} = \begin{bmatrix} \sum_{j=1}^k a_j \{ y_{ij} - p_{ij} \} \\ \sum_{i=1}^n \theta_i \{ y_{ij} - p_{ij} \} \\ \sum_{i=1}^n \{ p_{ij} - y_{ij} \} \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix} = \mathbf{0} \tag{3.11}$$

dengan  $\boldsymbol{\theta} = (\theta_1, \dots, \theta_n)$  dan  $\boldsymbol{\xi} = (\xi_1, \dots, \xi_k)$ ,  $\xi_j = (a_j, b_j)$ ,  $j = 1, \dots, k$  menyatakan vektor dari parameter-parameter yang tidak diketahui.

Sedangkan turunan parsial kedua dari  $I(\boldsymbol{\theta}, \boldsymbol{\xi})$  terhadap  $\theta_i$ ,  $a_j$ , dan  $b_j$  adalah sebagai berikut:

$$\begin{aligned}
\frac{\partial^2 I(\boldsymbol{\theta}, \boldsymbol{\xi})}{\partial \theta_i^2} &= \frac{\partial}{\partial \theta_i} \left( \frac{\partial I(\boldsymbol{\theta}, \boldsymbol{\xi})}{\partial \theta_i} \right) , i = 1, \dots, n \\
&= \frac{\partial}{\partial \theta_i} \left( \sum_{j=1}^k a_j (y_{ij} - p_{ij}) \right) \\
&= \sum_{j=1}^k \frac{\partial}{\partial \theta_i} (a_j y_{ij} - a_j p_{ij}) \\
&= \sum_{j=1}^k -a_j \left( \frac{\partial p_{ij}}{\partial \theta_i} \right) \\
&= \sum_{j=1}^k -a_j (a_j \cdot p_{ij} \cdot q_{ij}) \\
\frac{\partial^2 I(\boldsymbol{\theta}, \boldsymbol{\xi})}{\partial \theta_i^2} &= -\sum_{j=1}^k a_j^2 \cdot p_{ij} \cdot q_{ij} , i = 1, \dots, n \quad (3.12)
\end{aligned}$$
  

$$\begin{aligned}
\frac{\partial^2 I(\boldsymbol{\theta}, \boldsymbol{\xi})}{\partial a_j^2} &= \frac{\partial}{\partial a_j} \left( \frac{\partial I(\boldsymbol{\theta}, \boldsymbol{\xi})}{\partial a_j} \right) , j = 1, \dots, k \\
&= \frac{\partial}{\partial a_j} \left( \sum_{i=1}^n \theta_i (y_{ij} - p_{ij}) \right) \\
&= \sum_{i=1}^n \frac{\partial}{\partial a_j} (\theta_i y_{ij} - \theta_i p_{ij})
\end{aligned}$$

$$\begin{aligned}
&= \sum_{i=1}^n -\theta_i \left( \frac{\partial p_{ij}}{\partial a_j} \right) \\
&= \sum_{i=1}^n -\theta_i (\theta_i \cdot p_{ij} \cdot q_{ij}) \\
&= \sum_{i=1}^n -\theta_i^2 \cdot p_{ij} \cdot q_{ij}
\end{aligned}$$

$$\frac{\partial^2 I(\boldsymbol{\theta}, \boldsymbol{\xi})}{\partial a_j^2} = -\sum_{i=1}^n \theta_i^2 \cdot \left( \frac{e^{a_j \theta_i - b_j}}{1 + e^{a_j \theta_i - b_j}} \right) \cdot \left( \frac{1}{1 + e^{a_j \theta_i - b_j}} \right), j = 1, \dots, k \quad (3.13)$$

$$\frac{\partial^2 I(\boldsymbol{\theta}, \boldsymbol{\xi})}{\partial b_j \partial a_j} = \frac{\partial}{\partial b_j} \left( \frac{\partial I(\boldsymbol{\theta}, \boldsymbol{\xi})}{\partial a_j} \right), j = 1, \dots, k$$

$$= \frac{\partial}{\partial b_j} \left( \sum_{i=1}^n \theta_i \{y_{ij} - p_{ij}\} \right)$$

$$= \sum_{i=1}^n \frac{\partial}{\partial b_j} (\theta_i y_{ij} - \theta_i p_{ij})$$

$$= \sum_{i=1}^n -\theta_i \left( \frac{\partial p_{ij}}{\partial b_j} \right)$$

$$= \sum_{i=1}^n -\theta_i (-p_{ij} \cdot q_{ij})$$

$$= \sum_{i=1}^n \theta_i \cdot p_{ij} \cdot q_{ij}$$

$$\frac{\partial^2 I(\boldsymbol{\theta}, \boldsymbol{\xi})}{\partial b_j \partial a_j} = \sum_{i=1}^n \theta_i \cdot \left( \frac{e^{a_j \theta_i - b_j}}{1 + e^{a_j \theta_i - b_j}} \right) \cdot \left( \frac{1}{1 + e^{a_j \theta_i - b_j}} \right), j = 1, \dots, k \quad (3.14)$$

$$\begin{aligned}
\frac{\partial^2 I(\boldsymbol{\theta}, \boldsymbol{\xi})}{\partial \mathbf{a}_j \partial b_j} &= \frac{\partial}{\partial \mathbf{a}_j} \left( \frac{\partial I(\boldsymbol{\theta}, \boldsymbol{\xi})}{\partial b_j} \right) , j = 1, \dots, k \\
&= \frac{\partial}{\partial \mathbf{a}_j} \left( \sum_{i=1}^n \{ p_{ij} - y_{ij} \} \right) \\
&= \sum_{i=1}^n \frac{\partial}{\partial \mathbf{a}_j} (p_{ij} - y_{ij}) \\
&= \sum_{i=1}^n \frac{\partial p_{ij}}{\partial \mathbf{a}_j} \\
&= \sum_{i=1}^n \theta_i \cdot p_{ij} \cdot q_{ij} \\
\frac{\partial^2 I(\boldsymbol{\theta}, \boldsymbol{\xi})}{\partial \mathbf{a}_j \partial b_j} &= \sum_{i=1}^n \theta_i \cdot \left( \frac{e^{a_j \theta_i - b_j}}{1 + e^{a_j \theta_i - b_j}} \right) \cdot \left( \frac{1}{1 + e^{a_j \theta_i - b_j}} \right) , j = 1, \dots, k \quad (3.15)
\end{aligned}$$

dan

$$\begin{aligned}
\frac{\partial^2 I(\boldsymbol{\theta}, \boldsymbol{\xi})}{\partial b_j^2} &= \frac{\partial}{\partial b_j} \left( \frac{\partial I(\boldsymbol{\theta}, \boldsymbol{\xi})}{\partial b_j} \right) , j = 1, \dots, k \\
&= \frac{\partial}{\partial b_j} \left( \sum_{i=1}^n \{ p_{ij} - y_{ij} \} \right) \\
&= \sum_{i=1}^n \frac{\partial}{\partial b_j} (p_{ij} - y_{ij}) \\
&= \sum_{i=1}^n \frac{\partial p_{ij}}{\partial b_j} \\
&= \sum_{i=1}^n -p_{ij} \cdot q_{ij}
\end{aligned}$$

$$\frac{\partial^2 I(\boldsymbol{\theta}, \boldsymbol{\xi})}{\partial b_j^2} = - \sum_{i=1}^n \left( \frac{e^{a_i \theta_i - b_j}}{1 + e^{a_i \theta_i - b_j}} \right) \cdot \left( \frac{1}{1 + e^{a_i \theta_i - b_j}} \right), \quad j = 1, \dots, k \quad (3.16)$$

Matriks turunan kedua dari  $I(\boldsymbol{\theta}, \boldsymbol{\xi})$  terhadap  $a_j$ , dan  $b_j$  disebut juga matriks *Hessian*, menjadi:

$$\begin{aligned} H(\boldsymbol{\theta}, \boldsymbol{\xi}) &= \begin{bmatrix} H_{a_j a_j}(\boldsymbol{\theta}, \boldsymbol{\xi}) & H_{b_j a_j}(\boldsymbol{\theta}, \boldsymbol{\xi}) \\ H_{a_j b_j}(\boldsymbol{\theta}, \boldsymbol{\xi}) & H_{b_j b_j}(\boldsymbol{\theta}, \boldsymbol{\xi}) \end{bmatrix} \\ &= \begin{bmatrix} \frac{\partial^2 I(\boldsymbol{\theta}, \boldsymbol{\xi})}{\partial a_j^2} & \frac{\partial^2 I(\boldsymbol{\theta}, \boldsymbol{\xi})}{\partial b_j \partial a_j} \\ \frac{\partial^2 I(\boldsymbol{\theta}, \boldsymbol{\xi})}{\partial a_j \partial b_j} & \frac{\partial^2 I(\boldsymbol{\theta}, \boldsymbol{\xi})}{\partial b_j^2} \end{bmatrix} \\ &= \begin{bmatrix} - \sum_{i=1}^n \theta_i^2 \cdot \left( \frac{e^{a_i \theta_i - b_j}}{1 + e^{a_i \theta_i - b_j}} \right) \cdot \left( \frac{1}{1 + e^{a_i \theta_i - b_j}} \right) & \sum_{i=1}^n \theta_i \cdot \left( \frac{e^{a_i \theta_i - b_j}}{1 + e^{a_i \theta_i - b_j}} \right) \cdot \left( \frac{1}{1 + e^{a_i \theta_i - b_j}} \right) \\ \sum_{i=1}^n \theta_i \cdot \left( \frac{e^{a_i \theta_i - b_j}}{1 + e^{a_i \theta_i - b_j}} \right) \cdot \left( \frac{1}{1 + e^{a_i \theta_i - b_j}} \right) & - \sum_{i=1}^n \left( \frac{e^{a_i \theta_i - b_j}}{1 + e^{a_i \theta_i - b_j}} \right) \cdot \left( \frac{1}{1 + e^{a_i \theta_i - b_j}} \right) \end{bmatrix} \end{aligned} \quad (3.17)$$

Karena persamaan (3.8), (3.9), dan (3.10) tidak linear dalam  $\theta_i$ ,  $a_j$ ,

dan  $b_j$  ( $i = 1, \dots, n$  ;  $j = 1, \dots, k$ ) maka untuk mencari taksiran  $\hat{\theta}_i$ ,  $\hat{a}_j$ , dan  $\hat{b}_j$

digunakan suatu metode numerik. Salah satu metode numerik yang dapat digunakan adalah metode *Newton Raphson*.

Dalam IRM, penggunaan metode *Newton Raphson* untuk mendapatkan taksiran  $\hat{\theta}_i$ ,  $\hat{a}_j$ , dan  $\hat{b}_j$  dilakukan dengan metode *Newton Raphson* dua tahap:

1. Tahap pertama

- a. Pilih taksiran awal dari parameter soal  $\xi$ , yaitu  $\xi^{(0)} = (\mathbf{a}^{(0)}, \mathbf{b}^{(0)})$ , dan anggap parameter soal tersebut diketahui.
- b. Pilih taksiran awal dari  $\theta_i$  yaitu  $\hat{\theta}_i^{(0)}$ ,  $i=1,\dots,n$ .
- c. Tentukan taksiran dari  $\theta_i$  pada iterasi ke - m+1 ( $m=0,1,\dots$ ), yaitu  $\hat{\theta}_i^{(m+1)}$ , secara iteratif menggunakan formula:

$$\hat{\theta}_i^{(m+1)} = \hat{\theta}_i^{(m)} - \frac{f'(\hat{\theta}_i^{(m)})}{f''(\hat{\theta}_i^{(m)})} \quad (3.18)$$

dengan:

$\hat{\theta}_i^{(m)}$  adalah taksiran dari  $\theta_i$  ( $i=1,\dots,n$ ) , pada iterasi ke - m

$f'(\hat{\theta}_i^{(m)})$  adalah fungsi turunan parsial pertama dari  $I(\theta, \xi)$  terhadap

$\theta_i$  ( $i=1,\dots,n$ ) , dengan parameter  $\xi^{(0)} = (\mathbf{a}^{(0)}, \mathbf{b}^{(0)})$  dan

dihitung pada  $\theta_i = \hat{\theta}_i^{(m)}$

$f''(\hat{\theta}_i^{(m)})$  adalah fungsi turunan parsial kedua dari  $I(\theta, \xi)$  terhadap

$\theta_i$  ( $i=1,\dots,n$ ) , dengan parameter  $\xi^{(0)} = (\mathbf{a}^{(0)}, \mathbf{b}^{(0)})$  dan

dihitung pada  $\theta_i = \hat{\theta}_i^{(m)}$

d. Hentikan proses iterasi jika  $\hat{\theta}_i^{(m+1)} \approx \hat{\theta}_i^{(m)}$  (misalkan

$\|\hat{\theta}_i^{(m+1)} - \hat{\theta}_i^{(m)}\| < 10^{-5}$ ), kemudian ambil  $\hat{\theta}_i^{(m+1)}$  sebagai taksiran  $\hat{\theta}_i$ .

e. Lakukan langkah ke - b sampai langkah ke – d untuk  $i=1,\dots,n$

sedemikian sehingga didapat taksiran  $\hat{\boldsymbol{\theta}} = (\hat{\theta}_1, \dots, \hat{\theta}_n)$

## 2. Tahap kedua

a. Gunakan taksiran  $\hat{\boldsymbol{\theta}} = (\hat{\theta}_1, \dots, \hat{\theta}_n)$  yang didapat pada tahap pertama dan anggap parameter *latent ability* tersebut diketahui.

b. Ambil nilai awal dari  $\hat{\boldsymbol{\xi}}_j^{(0)} = (\hat{a}_j^{(0)}, \hat{b}_j^{(0)})$ ,  $j=1,\dots,k$  yang digunakan pada tahap pertama sebagai taksiran awal dari  $\boldsymbol{\xi}_j = (a_j, b_j)$ ,  $j=1,\dots,k$

c. Tentukan taksiran dari  $\boldsymbol{\xi}_j$  pada iterasi ke –  $m+1$  ( $m=0,1,\dots$ ), yaitu  $\hat{\boldsymbol{\xi}}_j^{(m+1)}$  secara iteratif menggunakan formula:

$$\hat{\boldsymbol{\xi}}_j^{(m+1)} = \hat{\boldsymbol{\xi}}_j^{(m)} - \left\{ \mathbf{H} \left[ \hat{\boldsymbol{\xi}}_j^{(m)} \right] \right\}^{-1} \mathbf{f}' \left[ \hat{\boldsymbol{\xi}}_j^{(m)} \right] \quad (3.19)$$

dengan:

$\hat{\boldsymbol{\xi}}_j^{(m)}$  adalah taksiran dari  $\boldsymbol{\xi}_j$  pada iterasi ke –  $m$ ,

$\mathbf{f}' \left[ \hat{\boldsymbol{\xi}}_j^{(m)} \right]$  adalah vektor turunan parsial pertama dari  $I(\boldsymbol{\theta}, \boldsymbol{\xi})$  terhadap  $a_j$

dan  $b_j$  untuk  $\boldsymbol{\theta} = \hat{\boldsymbol{\theta}} = (\hat{\theta}_1, \dots, \hat{\theta}_n)$  dihitung pada  $\boldsymbol{\xi}_j = \hat{\boldsymbol{\xi}}_j^{(m)}$ ,

$\mathbf{H} \left[ \hat{\boldsymbol{\xi}}_j^{(m)} \right]$  adalah matriks turunan parsial kedua dari  $I(\boldsymbol{\theta}, \boldsymbol{\xi})$  terhadap  $a_j$ ,

$b_j$  dan  $a_j b_j$  untuk  $\boldsymbol{\theta} = \hat{\boldsymbol{\theta}} = (\hat{\theta}_1, \dots, \hat{\theta}_n)$  dihitung pada  $\boldsymbol{\xi}_j = \hat{\boldsymbol{\xi}}_j^{(m)}$ ,

(lihat penurunan formula (3.18) dan (3.19) pada lampiran 3)

Atau dalam bentuk matriks dapat ditulis sebagai:

$$\begin{aligned} \begin{bmatrix} \hat{a}_j \\ \hat{b}_j \end{bmatrix}^{(m+1)} &= \begin{bmatrix} \hat{a}_j \\ \hat{b}_j \end{bmatrix}^{(m)} - \left[ \begin{bmatrix} H_{a_j a_j}(\boldsymbol{\xi}_j) & H_{b_j a_j}(\boldsymbol{\xi}_j) \\ H_{a_j b_j}(\boldsymbol{\xi}_j) & H_{b_j b_j}(\boldsymbol{\xi}_j) \end{bmatrix}_{\boldsymbol{\xi}_j = \hat{\boldsymbol{\xi}}_j^{(m)}} \right]^{-1} \begin{bmatrix} f'_{a_j}[\boldsymbol{\xi}_j] \\ f'_{b_j}[\boldsymbol{\xi}_j] \end{bmatrix}_{\boldsymbol{\xi}_j = \hat{\boldsymbol{\xi}}_j^{(m)}} \\ &= \begin{bmatrix} \hat{a}_j \\ \hat{b}_j \end{bmatrix}^{(m)} - \left[ \begin{bmatrix} -\sum_{i=1}^n \theta_i^2 \cdot \left( \frac{e^{a_j \theta_i - b_j}}{1 + e^{a_j \theta_i - b_j}} \right) \cdot \left( \frac{1}{1 + e^{a_j \theta_i - b_j}} \right) & \sum_{i=1}^n \theta_i \cdot \left( \frac{e^{a_j \theta_i - b_j}}{1 + e^{a_j \theta_i - b_j}} \right) \cdot \left( \frac{1}{1 + e^{a_j \theta_i - b_j}} \right) \\ \sum_{i=1}^n \theta_i \cdot \left( \frac{e^{a_j \theta_i - b_j}}{1 + e^{a_j \theta_i - b_j}} \right) \cdot \left( \frac{1}{1 + e^{a_j \theta_i - b_j}} \right) & -\sum_{i=1}^n \left( \frac{e^{a_j \theta_i - b_j}}{1 + e^{a_j \theta_i - b_j}} \right) \cdot \left( \frac{1}{1 + e^{a_j \theta_i - b_j}} \right) \end{bmatrix}_{\boldsymbol{\xi}_j = \hat{\boldsymbol{\xi}}_j^{(m)}} \right]^{-1} \begin{bmatrix} \sum_{i=1}^n \theta_i \left\{ y_{ij} - \left( \frac{e^{a_j \theta_i - b_j}}{1 + e^{a_j \theta_i - b_j}} \right) \right\} \\ \sum_{i=1}^n \left\{ \left( \frac{e^{a_j \theta_i - b_j}}{1 + e^{a_j \theta_i - b_j}} \right) - y_{ij} \right\} \end{bmatrix}_{\boldsymbol{\xi}_j = \hat{\boldsymbol{\xi}}_j^{(m)}} \end{aligned} \quad (3.20)$$

dengan  $m = 0, 1, 2, \dots$

d. Hentikan proses iterasi jika  $\hat{\boldsymbol{\xi}}_j^{(m+1)} = \begin{bmatrix} \hat{a}_j \\ \hat{b}_j \end{bmatrix}^{(m+1)} \approx \hat{\boldsymbol{\xi}}_j^{(m)} = \begin{bmatrix} \hat{a}_j \\ \hat{b}_j \end{bmatrix}^{(m)}$  (misalkan

$\|\hat{\boldsymbol{\xi}}_j^{(m+1)} - \hat{\boldsymbol{\xi}}_j^{(m)}\| < 10^{-5}$ ), kemudian ambil  $\hat{\boldsymbol{\xi}}_j^{(m+1)}$  sebagai taksiran

$$\hat{\boldsymbol{\xi}}_j = (\hat{a}_j, \hat{b}_j).$$

e. Lakukan langkah ke - b sampai langkah ke - d untuk  $j=1, \dots, k$

sedemikian sehingga didapat taksiran  $(\hat{\mathbf{a}}, \hat{\mathbf{b}}) = (\hat{a}_1, \dots, \hat{a}_k, \hat{b}_1, \dots, \hat{b}_k)$

Pada tahap pertama metode *Newton Raphson*, jika diasumsikan

parameter soal  $\boldsymbol{\xi}$  pada persamaan (3.4) diketahui maka nilai  $\boldsymbol{\theta} = (\theta_1, \dots, \theta_n)$

yang diperoleh sebagai hasil penyelesaian dari persamaan (3.8) akan

memaksimumkan  $I(\boldsymbol{\theta})$  jika  $\left(\frac{\partial^2 I(\boldsymbol{\theta})}{\partial \theta_i^2}\right) < 0$ .

Telah ditunjukkan pada persamaan (3.12) bahwa  $\left(\frac{\partial^2 I(\boldsymbol{\theta})}{\partial \theta_i^2}\right) < 0$ , oleh

karena itu nilai  $\boldsymbol{\theta} = (\theta_1, \dots, \theta_n)$  yang memenuhi persamaan (3.8) dikatakan

memaksimumkan  $I(\boldsymbol{\theta})$ . Nilai  $\boldsymbol{\theta}$  ini disebut taksiran maksimum *likelihood* dan dinotasikan dengan  $\hat{\boldsymbol{\theta}} = (\hat{\theta}_1, \dots, \hat{\theta}_n)$ . Nilai taksiran  $\hat{\boldsymbol{\theta}}$  ini dicari menggunakan tahap pertama metode *Newton Raphson* diatas.

Sedangkan pada tahap kedua metode *Newton Raphson*, jika diasumsikan parameter *latent ability* pada persamaan (3.4) diketahui maka nilai  $\boldsymbol{\xi} = (\xi_1, \dots, \xi_k)$ ,  $\xi_j = (a_j, b_j)$   $j = 1, \dots, k$  yang diperoleh sebagai hasil penyelesaian dari persamaan (3.9), dan (3.10) akan memaksimumkan  $I(\boldsymbol{\xi})$  jika

$$\Delta = \left\{ \left( \frac{\partial^2 I(\boldsymbol{\xi})}{\partial a_j^2} \right) \left( \frac{\partial^2 I(\boldsymbol{\xi})}{\partial b_j^2} \right) - \left( \frac{\partial^2 I(\boldsymbol{\xi})}{\partial a_j \partial b_j} \right)^2 \right\} > 0 \quad (3.21)$$

dan  $\left( \frac{\partial^2 I(\boldsymbol{\xi})}{\partial a_j^2} \right) < 0$  atau  $\left( \frac{\partial^2 I(\boldsymbol{\xi})}{\partial b_j^2} \right) < 0$ .

Telah ditunjukkan pada lampiran 4 bahwa  $\Delta > 0$  dan  $\left( \frac{\partial^2 I(\xi)}{\partial a_j^2} \right) < 0$

atau  $\left( \frac{\partial^2 I(\xi)}{\partial b_j^2} \right) < 0$ , oleh karena itu nilai  $\xi = (\xi_1, \dots, \xi_k)$ ,  $\xi_j = (a_j, b_j)$  yang

memenuhi persamaan (3.9), dan (3.10) dikatakan memaksimumkan  $I(\xi)$ .

Nilai  $\xi$  ini disebut taksiran maksimum *likelihood* dan dinotasikan dengan

$\hat{\xi} = (\hat{\xi}_1, \dots, \hat{\xi}_k)$ ,  $\hat{\xi}_j = (\hat{a}_j, \hat{b}_j)$ . Nilai taksiran  $\hat{\xi}$  ini dicari menggunakan tahap

kedua metode *Newton Raphson*.

Setelah mendapatkan taksiran *Newton Raphson* dari  $\xi$  pada tahap kedua, ulang kembali tahap pertama dengan menggunakan taksiran parameter soal  $\xi$  yang baru sebagai parameter yang diketahui untuk mendapatkan taksiran baru dari  $\theta$ . Metode *Newton Raphson* dua tahap ini diulang terus sampai parameter *latent ability* dan parameter soal konvergen ke suatu nilai.

Dalam metode *Newton Raphson* dua tahap diatas digunakan nilai  $\theta$  yang telah distandarisasi (mempunyai mean nol dan standar deviasi satu) disetiap iterasi. Maka estimasi dari parameter soal yang didapat juga merupakan nilai yang terstandarisasi.

### 3.5 Seleksi Soal

Telah dijelaskan diawal bab ini bahwa tujuan dari IRM adalah untuk membangun suatu alat tes yang baik. Tingkat kebaikan suatu soal ditentukan berdasarkan *Fisher Information* yang disebut *item information function*.

*Item information function* untuk soal ke-j peserta ke - i, dinotasikan dengan  $I_j(\theta_i)$ , menyatakan banyaknya informasi yang dimiliki soal ke-j terhadap *ability* peserta ke-i,  $\theta_i$ . Dapat diartikan bahwa semakin besar nilai  $I_j(\theta_i)$  maka semakin baik soal ke-j dalam mengukur  $\theta_i$ .

Misalkan  $Y_{ij}$  adalah variabel random jawaban soal ke – j dari peserta ke-i dengan ability parameter  $\theta_i$  dengan pdf

$$f(y_{ij};\theta_i) = F(a_j\theta_i - b_j)^{y_{ij}} [1 - F(a_j\theta_i - b_j)]^{1-y_{ij}} \quad (3.22)$$

dengan  $y_{ij} = 0,1$  dan  $j=1,\dots,k$ ,  $i=1,\dots,n$ .

Misalkan  $p_{ij} = F(a_j\theta_i - b_j)$  dan  $q_{ij} = 1 - p_{ij} = 1 - F(a_j\theta_i - b_j)$ , maka persamaan (3.22) dapat ditulis sebagai

$$f(y_{ij};\theta_i) = p_{ij}^{y_{ij}} q_{ij}^{1-y_{ij}} \quad (3.23)$$

Fungsi logaritma natural dari persamaan (3.22) diberikan sebagai

$$\ln f(y_{ij};\theta_i) = y_{ij} \ln p_{ij} + (1-y_{ij})q_{ij} \quad (3.24)$$

Turunan pertama dari persamaan (3.24) terhadap  $\theta_i$  diberikan sebagai

$$\begin{aligned}
\frac{\partial \ln f(y_{ij}; \theta_i)}{\partial \theta_i} &= \frac{\partial}{\partial \theta_i} [y_{ij} \ln p_{ij} + (1-y_{ij})q_{ij}] \\
&= y_{ij} \frac{\partial \ln p_{ij}}{\partial \theta_i} + (1-y_{ij}) \frac{\partial \ln q_{ij}}{\partial \theta_i} \\
&= \frac{y_{ij}}{p_{ij}} \frac{\partial p_{ij}}{\partial \theta_i} + \frac{(1-y_{ij})}{q_{ij}} \frac{\partial q_{ij}}{\partial \theta_i}, \text{ substitusi persamaan (3.7)} \\
&= \frac{y_{ij}}{p_{ij}} a_j p_{ij} q_{ij} + \frac{(1-y_{ij})}{q_{ij}} \frac{\partial (1-p_{ij})}{\partial \theta_i}, \text{ substitusi persamaan (3.7)} \\
&= y_{ij} a_j q_{ij} + \frac{(1-y_{ij})}{q_{ij}} (-a_j p_{ij} q_{ij}) \\
&= y_{ij} a_j (1-p_{ij}) - a_j p_{ij} + y_{ij} a_j p_{ij} \\
&= y_{ij} a_j - y_{ij} a_j p_{ij} - a_j p_{ij} + y_{ij} a_j p_{ij} \\
\frac{\partial \ln f(y_{ij}; \theta_i)}{\partial \theta_i} &= a_j (y_{ij} - p_{ij}) \tag{3.25}
\end{aligned}$$

Turunan kedua dari persamaan (3.24) terhadap  $\theta_i$  diberikan sebagai berikut

$$\begin{aligned}
\frac{\partial^2 \ln f(y_{ij}; \theta_i)}{\partial \theta_i^2} &= \frac{\partial}{\partial \theta_i} \left[ \frac{\partial \ln f(y_{ij}; \theta_i)}{\partial \theta_i} \right] \\
&= \frac{\partial}{\partial \theta_i} [a_j y_{ij} - a_j p_{ij}] \\
&= -a_j \frac{\partial p_{ij}}{\partial \theta_i} \\
&= -a_j^2 p_{ij} q_{ij} \tag{3.26}
\end{aligned}$$

Berdasarkan *Fisher Information* maka *item information function*, dinotasikan dengan  $I_j(\theta_i)$ , dapat ditulis dalam bentuk

$$\begin{aligned}
 I_j(\theta_i) &= -\sum_{y_{ij}=0}^1 \frac{\partial^2 \ln f(y_{ij}; \theta_i)}{\partial \theta_i^2} \cdot f(y_{ij}; \theta_i) \\
 &= -\left[ (-a_j^2 p_{ij} q_{ij}) (p_{ij}^0 q_{ij}^{1-0}) + (-a_j^2 p_{ij} q_{ij}) (p_{ij}^1 q_{ij}^{1-1}) \right] \\
 &= -\left[ (-a_j^2 p_{ij} q_{ij}) q_{ij} + (-a_j^2 p_{ij} q_{ij}) p_{ij} \right] \\
 &= -(-a_j^2 p_{ij} q_{ij}) (q_{ij} + p_{ij}) \\
 &= (a_j^2 p_{ij} q_{ij}) [(1 - p_{ij}) + p_{ij}] \\
 I_j(\theta_i) &= a_j^2 p_{ij} q_{ij}
 \end{aligned} \tag{3.27}$$

Setelah memperoleh nilai  $I_j(\theta_i)$  untuk setiap soal ke- $j$  peserta ke- $i$ , maka langkah berikutnya adalah menghitung total informasi yang dimiliki seluruh soal untuk peserta ke –  $i$  yaitu dengan menjumlahkan  $I_j(\theta_i)$  untuk seluruh soal.

Notasikan total informasi untuk peserta ke –  $i$  adalah

$$A(\theta_i) = \sum_{j=1}^k I_j(\theta_i) \tag{3.28}$$

$A(\theta_i)$  dikenal dengan sebutan *test information function*. Selanjutnya dapat ditunjukkan bahwa  $A(\theta_i) = I(\theta_i)$  dimana  $I(\theta_i)$  adalah *Fisher Information*.

Bukti:

$$\text{Pandang } A(\theta_i) = \sum_{j=1}^k I_j(\theta_i).$$

Akan dibuktikan bahwa  $A(\theta_i) = I(\theta_i)$ , dengan perkataan lain akan dibuktikan

$$\text{bahwa } I(\theta_i) = \sum_{j=1}^k I_j(\theta_i).$$

Misalkan  $Y_{i1}, \dots, Y_{ik}$  adalah variabel random jawaban soal yang independen dari peserta ke-  $i$  dengan *latent ability*  $\theta_i$  dengan pdf  $f(y_{ij}; \theta_i)$ ,  $j = 1, \dots, k$ .

Maka fungsi *likelihood* dapat diberikan sebagai

$$\begin{aligned} L(\theta_i) &= L(\theta_i; y_{i1}, \dots, y_{ik}) \\ &= f(y_{i1}, \dots, y_{ik}; \theta_i) \\ L(\theta_i) &= f(y_{i1}; \theta_i) \times \dots \times f(y_{ik}; \theta_i) \end{aligned}$$

Bentuk logaritma dari persamaan diatas adalah

$$\ln L(\theta_i) = \ln f(y_{i1}; \theta_i) + \dots + \ln f(y_{ik}; \theta_i)$$

Dan

$$\frac{\partial \ln L(\theta_i)}{\partial \theta_i} = \frac{\partial \ln f(y_{i1}; \theta_i)}{\partial \theta_i} + \dots + \frac{\partial \ln f(y_{ik}; \theta_i)}{\partial \theta_i} \quad (3.29)$$

Maka *Fisher Information* dapat diberikan sebagai

$$I(\theta_i) = E \left\{ \left[ \frac{\partial \ln L(\theta_i)}{\partial \theta_i} \right]^2 \right\} \quad (3.30)$$

Jika persamaan (3.29) dikuadratkan maka akan didapat bentuk perkalian, yaitu

$$2E\left\{\frac{\partial \ln f(y_{im}; \theta_i)}{\partial \theta_i} \cdot \frac{\partial \ln f(y_{in}; \theta_i)}{\partial \theta_i}\right\}, \quad m \neq n$$

Karena  $Y_{im}$  dan  $Y_{in}$  saling independen dan berdasarkan persamaan (2) *Fisher Information* (pada landasan teori), maka dapat ditulis

$$\begin{aligned} & 2E\left\{\frac{\partial \ln f(y_{im}; \theta_i)}{\partial \theta_i}\right\} \cdot E\left\{\frac{\partial \ln f(y_{in}; \theta_i)}{\partial \theta_i}\right\} \\ &= 2\left\{\int_{-\infty}^{\infty} \frac{\partial \ln f(y_{im}; \theta_i)}{\partial \theta_i} \cdot f(y_{im}; \theta_i) dy_{im}\right\} \cdot \left\{\int_{-\infty}^{\infty} \frac{\partial \ln f(y_{in}; \theta_i)}{\partial \theta_i} \cdot f(y_{in}; \theta_i) dy_{in}\right\} \\ &= 0 \end{aligned}$$

Oleh karena itu *Fisher Information* pada persamaan (3.30) dapat diberikan sebagai

$$\begin{aligned} I(\theta_i) &= \sum_{j=1}^k E\left\{\left[\frac{\partial \ln f(y_{ij}; \theta_i)}{\partial \theta_i}\right]^2\right\} \\ &= \sum_{j=1}^k E\left\{-\frac{\partial^2 \ln f(y_{ij}; \theta_i)}{\partial \theta_i^2}\right\} \\ I(\theta_i) &= \sum_{j=1}^k I_j(\theta_i), \quad i = 1, \dots, n \end{aligned} \tag{terbukti}$$

Karena terdapat  $n$ -peserta tes dengan *latent ability*  $\theta_1, \dots, \theta_n$  maka *test information function* dilakukan terhadap setiap  $\theta_i, i = 1, \dots, n$ . Pilih  $\theta$  yang memiliki nilai  $A(\theta)$  terbesar. Tingkat kebaikan soal dapat diurutkan berdasarkan nilai  $I_j(\theta)$ . Semakin besar nilai  $I_j(\theta)$  yang dimiliki suatu soal maka semakin baik soal tersebut. Sejumlah  $n$ -soal terbaik dipilih untuk dijadikan alat tes yang baru.

## BAB IV

### APLIKASI

Dalam skripsi ini IRM akan diaplikasikan untuk mengevaluasi soal tes matematika. Dengan IRM, diharapkan soal tes tersebut mampu mengukur kemampuan matematika para peserta tes dengan tepat.

#### 4.1 Data

Data berasal dari hasil tes matematika semester genap tahun ajaran 2007-2008 siswa SMP XYZ kelas VII di kota A. Lampiran 5 memuat data jawaban tes matematika yang terdiri dari 30 soal dan diikuti oleh 143 peserta tes.

#### 4.2 Analisis Data

Berdasarkan data diatas akan dicari taksiran parameter *latent ability*, diskriminasi soal dan kesulitan soal dan kemudian akan dilakukan seleksi soal terbaik berdasarkan taksiran parameter yang didapat.

Dengan menggunakan *software* MATLAB versi 5.3 diperoleh taksiran parameter *latent ability* dan karakteristik soal (tingkat diskriminasi dan kesulitan soal). Tabel 1 menampilkan taksiran parameter *latent*

*ability*,  $\theta$ , dari 143 peserta dan tabel 2 menampilkan taksiran parameter diskriminasi soal, a, dan kesulitan soal, b, dari 30 soal yang dimasukkan kedalam tes.

**Tabel 1**  
Taksiran Parameter *Latent Ability*

$\theta$		$\theta$		$\theta$		$\theta$	
θ1	2.2466	θ37	1.4438	θ73	2.2466	θ109	1.1691
θ2	-0.478	θ38	0.5554	θ74	-0.2018	θ110	-0.756
θ3	-0.756	θ39	-0.756	θ75	-0.6162	θ111	-0.478
θ4	0.3885	θ40	-0.3402	θ76	-0.2018	θ112	2.2466
θ5	0.5554	θ41	-1.1988	θ77	0.9383	θ113	1.787
θ6	-0.0613	θ42	-0.756	θ78	0.3885	θ114	-0.756
θ7	0.9383	θ43	-1.0455	θ79	-0.0613	θ115	0.0827
θ8	-0.6162	θ44	-1.1988	θ80	-0.0613	θ116	-0.478
θ9	0.2319	θ45	-1.1988	θ81	-0.478	θ117	1.4438
θ10	0.0827	θ46	1.1691	θ82	-1.0455	θ118	-0.756
θ11	-0.6162	θ47	0.0827	θ83	-0.6162	θ119	1.1691
θ12	2.2466	θ48	-0.6162	θ84	-0.3402	θ120	0.2319
θ13	0.7367	θ49	-1.3614	θ85	0.3885	θ121	1.787
θ14	0.9383	θ50	-0.756	θ86	-0.6162	θ122	-0.756
θ15	-0.6162	θ51	-0.0613	θ87	0.3885	θ123	-0.8986
θ16	0.7367	θ52	-1.3614	θ88	-0.6162	θ124	-1.0455
θ17	-0.478	θ53	0.5554	θ89	-0.478	θ125	1.4438
θ18	0.5554	θ54	0.9383	θ90	-0.6162	θ126	-0.478
θ19	-0.0613	θ55	1.4438	θ91	2.2466	θ127	0.2319
θ20	4.2863	θ56	0.5554	θ92	-1.3614	θ128	-1.3614
θ21	-0.0613	θ57	1.1691	θ93	-0.0613	θ129	-1.9687
θ22	-0.6162	θ58	0.2319	θ94	0.7367	θ130	-0.3402
θ23	0.5554	θ59	0.2319	θ95	-0.8986	θ131	-0.3402
θ24	-1.1988	θ60	-0.8986	θ96	-0.0613	θ132	0.9383
θ25	-0.3402	θ61	-0.2018	θ97	0.3885	θ133	-0.3402
θ26	0.9383	θ62	-0.6162	θ98	-0.6162	θ134	-1.538
θ27	-1.0455	θ63	-1.3614	θ99	-1.538	θ135	-0.0613
θ28	-0.756	θ64	-0.6162	θ100	-0.478	θ136	2.2466

θ29	0.7367	θ65	-0.0613	θ101	0.3885	θ137	-0.8986
θ30	0.3885	θ66	-1.1988	θ102	-0.6162	θ138	0.2319
θ31	-0.0613	θ67	-0.478	θ103	-0.3402	θ139	0.0827
θ32	2.2466	θ68	-0.0613	θ104	-0.8986	θ140	0.0827
θ33	-0.478	θ69	-0.6162	θ105	0.0827	θ141	0.2319
θ34	-0.6162	θ70	-0.756	θ106	-0.756	θ142	1.1691
θ35	-0.6162	θ71	-1.0455	θ107	0.3885	θ143	2.2466
	θ36	-0.2018	θ72	0.3885	θ108	0.0827	

**Tabel 2**

Taksiran Parameter Diskriminasi Soal dan Kesulitan Soal

a		a		b		b	
a1	1.5743	a16	0.7245	b1	-1.8564	b16	1.1925
a2	0.9021	a17	0.7967	b2	0.8334	b17	-0.6555
a3	1.0917	a18	1.1427	b3	0.628	b18	-0.5707
a4	1.0974	a19	1.4161	b4	0.0222	b19	-1.7221
a5	1.1494	a20	0.7848	b5	0.594	b20	0.4362
a6	2.0126	a21	0.2402	b6	-1.95	b21	-1.3005
a7	1.9277	a22	2.1656	b7	0.3079	b22	-2.9173
a8	1.2795	a23	0.1474	b8	-0.3204	b23	-0.0706
a9	1.5319	a24	1.3732	b9	-1.4554	b24	-0.5234
a10	1.3312	a25	0.8015	b10	0.1056	b25	-0.5902
a11	2.2758	a26	0.6419	b11	-0.6568	b26	0.0586
a12	1.0833	a27	0.7642	b12	-1.3416	b27	-0.5495
a13	0.6059	a28	1.8516	b13	0.8994	b28	-0.6185
a14	2.1149	a29	0.9038	b14	-3.0369	b29	0.0081
a15	1.3601	a30	2.1025	b15	0.4073	b30	1.1292

Setelah memperoleh nilai taksiran dari tiap parameter, maka dapat dihitung nilai *test information function* untuk setiap peserta tes. Tabel 3 menampilkan *test information function* untuk setiap *latent ability* peserta tes.

**Tabel 3***Test Information Function Peserta Tes*

TI $\theta$		TI $\theta$		TI $\theta$		TI $\theta$	
TI $\theta$ 1	1.8067	TI $\theta$ 37	3.7954	TI $\theta$ 73	1.8067	TI $\theta$ 109	4.8668
TI $\theta$ 2	10.4204	TI $\theta$ 38	7.7058	TI $\theta$ 74	10.1924	TI $\theta$ 110	10.2711
TI $\theta$ 3	10.2711	TI $\theta$ 39	10.2711	TI $\theta$ 75	10.3902	TI $\theta$ 111	10.4204
TI $\theta$ 4	8.4334	TI $\theta$ 40	10.3569	TI $\theta$ 76	10.1924	TI $\theta$ 112	1.8067
TI $\theta$ 5	7.7058	TI $\theta$ 41	9.283	TI $\theta$ 77	5.9046	TI $\theta$ 113	2.7546
TI $\theta$ 6	9.9207	TI $\theta$ 42	10.2711	TI $\theta$ 78	8.4334	TI $\theta$ 114	10.2711
TI $\theta$ 7	5.9046	TI $\theta$ 43	9.7395	TI $\theta$ 79	9.9207	TI $\theta$ 115	9.5382
TI $\theta$ 8	10.3902	TI $\theta$ 44	9.283	TI $\theta$ 80	9.9207	TI $\theta$ 116	10.4204
TI $\theta$ 9	9.0432	TI $\theta$ 45	9.283	TI $\theta$ 81	10.4204	TI $\theta$ 117	3.7954
TI $\theta$ 10	9.5382	TI $\theta$ 46	4.8668	TI $\theta$ 82	9.7395	TI $\theta$ 118	10.2711
TI $\theta$ 11	10.3902	TI $\theta$ 47	9.5382	TI $\theta$ 83	10.3902	TI $\theta$ 119	4.8668
TI $\theta$ 12	1.8067	TI $\theta$ 48	10.3902	TI $\theta$ 84	10.3569	TI $\theta$ 120	9.0432
TI $\theta$ 13	6.8599	TI $\theta$ 49	8.6526	TI $\theta$ 85	8.4334	TI $\theta$ 121	2.7546
TI $\theta$ 14	5.9046	TI $\theta$ 50	10.2711	TI $\theta$ 86	10.3902	TI $\theta$ 122	10.2711
TI $\theta$ 15	10.3902	TI $\theta$ 51	9.9207	TI $\theta$ 87	8.4334	TI $\theta$ 123	10.0594
TI $\theta$ 16	6.8599	TI $\theta$ 52	8.6526	TI $\theta$ 88	10.3902	TI $\theta$ 124	9.7395
TI $\theta$ 17	10.4204	TI $\theta$ 53	7.7058	TI $\theta$ 89	10.4204	TI $\theta$ 125	3.7954
TI $\theta$ 18	7.7058	TI $\theta$ 54	5.9046	TI $\theta$ 90	10.3902	TI $\theta$ 126	10.4204
TI $\theta$ 19	9.9207	TI $\theta$ 55	3.7954	TI $\theta$ 91	1.8067	TI $\theta$ 127	9.0432
TI $\theta$ 20	0.3412	TI $\theta$ 56	7.7058	TI $\theta$ 92	8.6526	TI $\theta$ 128	8.6526
TI $\theta$ 21	9.9207	TI $\theta$ 57	4.8668	TI $\theta$ 93	9.9207	TI $\theta$ 129	5.4217
TI $\theta$ 22	10.3902	TI $\theta$ 58	9.0432	TI $\theta$ 94	6.8599	TI $\theta$ 130	10.3569
TI $\theta$ 23	7.7058	TI $\theta$ 59	9.0432	TI $\theta$ 95	10.0594	TI $\theta$ 131	10.3569
TI $\theta$ 24	9.283	TI $\theta$ 60	10.0594	TI $\theta$ 96	9.9207	TI $\theta$ 132	5.9046
TI $\theta$ 25	10.3569	TI $\theta$ 61	10.1924	TI $\theta$ 97	8.4334	TI $\theta$ 133	10.3569
TI $\theta$ 26	5.9046	TI $\theta$ 62	10.3902	TI $\theta$ 98	10.3902	TI $\theta$ 134	7.8105
TI $\theta$ 27	9.7395	TI $\theta$ 63	8.6526	TI $\theta$ 99	7.8105	TI $\theta$ 135	9.9207
TI $\theta$ 28	10.2711	TI $\theta$ 64	10.3902	TI $\theta$ 100	10.4204	TI $\theta$ 136	1.8067
TI $\theta$ 29	6.8599	TI $\theta$ 65	9.9207	TI $\theta$ 101	8.4334	TI $\theta$ 137	10.0594
TI $\theta$ 30	8.4334	TI $\theta$ 66	9.283	TI $\theta$ 102	10.3902	TI $\theta$ 138	9.0432
TI $\theta$ 31	9.9207	TI $\theta$ 67	10.4204	TI $\theta$ 103	10.3569	TI $\theta$ 139	9.5382
TI $\theta$ 32	1.8067	TI $\theta$ 68	9.9207	TI $\theta$ 104	10.0594	TI $\theta$ 140	9.5382
TI $\theta$ 33	10.4204	TI $\theta$ 69	10.3902	TI $\theta$ 105	9.5382	TI $\theta$ 141	9.0432

TI $\theta$ 34	10.3902	TI $\theta$ 70	10.2711	TI $\theta$ 106	10.2711	TI $\theta$ 142	4.8668
TI $\theta$ 35	10.3902	TI $\theta$ 71	9.7395	TI $\theta$ 107	8.4334	TI $\theta$ 143	1.8067
	TI $\theta$ 36	10.1924	TI $\theta$ 72	8.4334	TI $\theta$ 108	9.5382	

TI $\theta$  = *Test Information* dari peserta tes dengan *latent ability*  $\theta$

Dari hasil tersebut diketahui bahwa nilai *test information function* terbesar adalah 10.4204 didapat oleh peserta dengan *latent ability*,  $\theta = -0,478$ . Langkah selanjutnya, dengan nilai  $\theta = -0,478$ , urutkan nilai *item information function* dari yang paling informatif sampai yang kurang informatif. Tabel 4 menampilkan nilai *item information function* untuk  $\theta = -0,478$ . Sedangkan Tabel 5 menampilkan nilai *item information function* untuk  $\theta = -0,478$  yang telah diurutkan dari yang paling informatif sampai yang kurang informatif.

**Tabel 4**

*Item Information Function* untuk  $\theta = -0,478$

I		I	
I1	0.4635	I16	0.0764
I2	0.1397	I17	0.1557
I3	0.2177	I18	0.3264
I4	0.2797	I19	0.3859
I5	0.2421	I20	0.1312
I6	0.8008	I21	0.0103
I7	0.6506	I22	0.5379
I8	0.4007	I23	0.0054
I9	0.5162	I24	0.4693
I10	0.3872	I25	0.1589
I11	1.2365	I26	0.0996
I12	0.2487	I27	0.1448

I13	0.0657	I28	0.8421
I14	0.4604	I29	0.1946
I15	0.3539	I30	0.4183

**Tabel 5**

*Item Information Function Untuk  $\theta = -0,478$  Yang Diurutkan*

sort_I		sort_I	
I11	11	I4	4
I28	28	I12	12
I6	6	I5	5
I7	7	I3	3
I22	22	I29	29
I9	9	I25	25
I24	24	I17	17
I1	1	I27	27
I14	14	I2	2
I30	30	I20	20
I8	8	I26	26
I10	10	I16	16
I19	19	I13	13
I15	15	I21	21
I18	18	I23	23

Pilih sejumlah n-soal yang paling informatif untuk dijadikan alat tes yang baru. Jumlah soal yang dipilih disesuaikan dengan kebutuhan.

## BAB V

## PENUTUP

### 5.1 Kesimpulan

Kesimpulan yang dapat diambil dari penulisan skripsi ini:

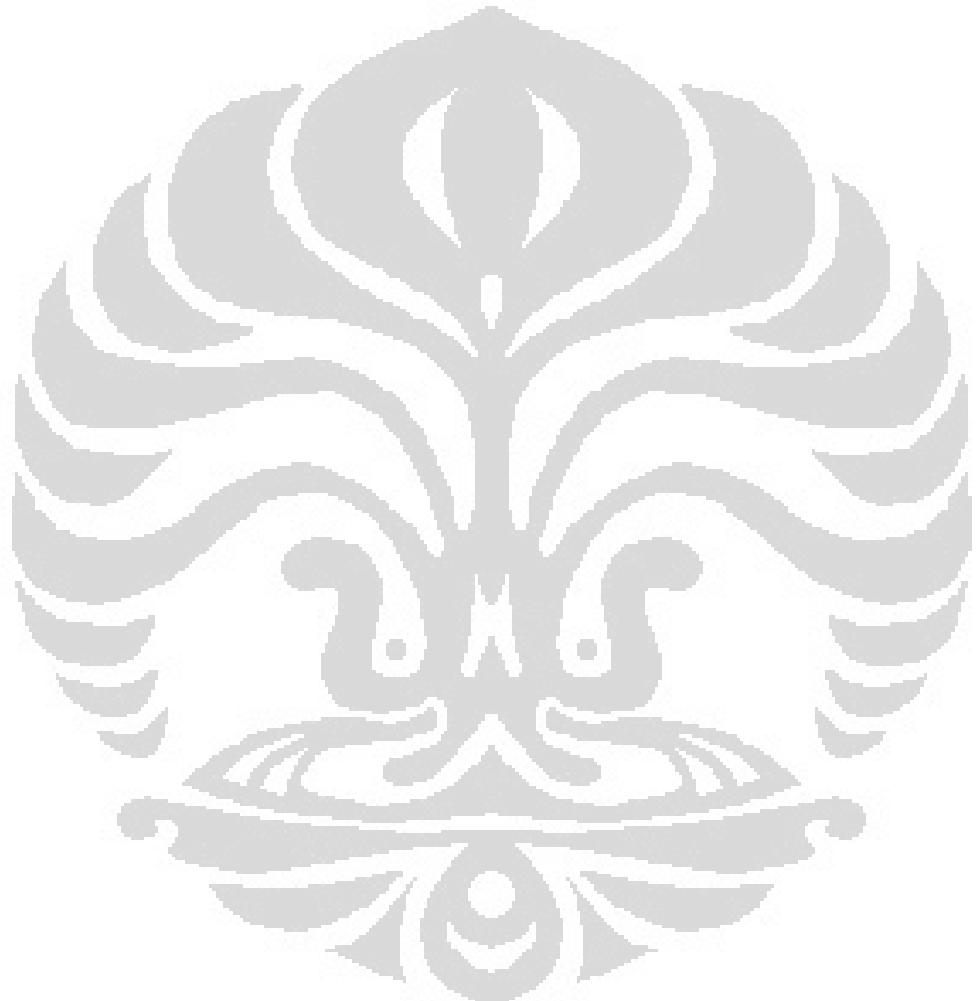
1. Taksiran parameter *latent ability*, diskriminasi soal dan kesulitan soal diperoleh dengan menggunakan metode penaksiran *joint maximum likelihood*.
2. Tingkat kebaikan setiap soal dapat dicari dan dibandingkan dengan menggunakan *item information function*.
3. *Item response model* cukup baik untuk menyeleksi soal berdasarkan parameter *latent ability*, diskriminasi soal dan kesulitan soal.

### 5.2 Saran

Saran untuk pengembangan skripsi ini:

1. *Item response model* dapat diaplikasikan dalam tes dengan format jawaban politomus.
2. Dalam memodelkan probabilitas jawaban peserta tes dapat ditambahkan parameter *guessing* (menebak) selain parameter *latent ability*, diskriminasi soal dan kesulitan soal.

3. Fungsi probabilitas jawaban soal dapat diasumsikan mengikuti fungsi distribusi dari distribusi normal standar.
4. Penaksiran parameter dapat dilakukan dengan metode lain seperti metode penaksiran *Marginal Maximum Likelihood* atau metode Bayes.



## DAFTAR PUSTAKA

- Baker, F.B. 2001. *The Basics of Item Response Theory*. ERIC Clearinghouse for Assessment and Evaluation.
- Embretson, S.E., Reise, S.P. 2000. *Item Response Model for Psychologists*. Lawrence Erlbaum.
- Hogg, R.V., Craig, A.T. 1995. *Introduction to Mathematical Statistics, fifth edition*. Prentice-Hall Inc., New Jersey.
- Hulin, C.L., Drasgow, F., Parsons, C.K. 1983. *Item Response Theory : Application to Psychological Measurement*. Dow Jones – Irwin, Illinois.
- Johnson, V.E., Albert, J.H. 2000. *Ordinal Data Modeling*. Springer-Verlag, New York.
- Pawitan, Y. 2001. *In All Likelihood : Statistical Modelling and Inference Using Likelihood*. Oxford University Press Inc., New York.
- Toribio, S.G. 2006. “Bayesian Model Checking Strategies for Dichotomous Item Response Theory Models”. Bowling Green University, Ohio.

## LAMPIRAN

### LAMPIRAN 1

Menunjukkan,  $\theta$  memaksimumkan  $L(\theta) \leftrightarrow \theta$  memaksimumkan  $\ln L(\theta)$

Bukti:

( $\rightarrow$ ) karena  $\theta$  memaksimumkan  $L(\theta)$  maka

$$\bullet \quad \frac{\partial L(\theta)}{\partial \theta} = 0,$$

$$\frac{\partial L(\theta)}{\partial \theta} = 0 \Leftrightarrow \frac{1}{L(\theta)} \cdot \frac{\partial L(\theta)}{\partial \theta} = \frac{1}{L(\theta)} \cdot 0 \Leftrightarrow \frac{\partial \ln L(\theta)}{\partial \theta} = 0$$

$$\bullet \quad \frac{\partial^2 L(\theta)}{\partial \theta^2} < 0,$$

$$\frac{\partial^2 L(\theta)}{\partial \theta^2} \cdot \frac{1}{L(\theta)} < 0 \cdot \frac{1}{L(\theta)} \Leftrightarrow \frac{\partial^2 L(\theta)}{\partial \theta^2} \cdot \frac{1}{L(\theta)} < 0$$

$$\Leftrightarrow \frac{\partial}{\partial \theta} \left( \frac{1}{L(\theta)} \right) \cdot \frac{\partial L(\theta)}{\partial \theta} + \frac{\partial^2 L(\theta)}{\partial \theta^2} \cdot \frac{1}{L(\theta)} < \frac{\partial}{\partial \theta} \left( \frac{1}{L(\theta)} \right) \cdot \frac{\partial L(\theta)}{\partial \theta} + 0$$

$$\Leftrightarrow \frac{\partial}{\partial \theta} \left( \frac{1}{L(\theta)} \right) \cdot \frac{\partial L(\theta)}{\partial \theta} + \frac{\partial^2 L(\theta)}{\partial \theta^2} \cdot \frac{1}{L(\theta)} < \frac{\partial}{\partial \theta} \left( \frac{1}{L(\theta)} \right) \cdot 0 + 0$$

$$\Leftrightarrow \frac{\partial}{\partial \theta} \left( \frac{1}{L(\theta)} \right) \cdot \frac{\partial L(\theta)}{\partial \theta} + \frac{\partial^2 L(\theta)}{\partial \theta^2} \cdot \frac{1}{L(\theta)} < 0$$

$$\Leftrightarrow \frac{\partial}{\partial \theta} \left( \frac{1}{L(\theta)} \cdot \frac{\partial L(\theta)}{\partial \theta} \right) < 0 \Leftrightarrow \frac{\partial}{\partial \theta} \left( \frac{\partial \ln L(\theta)}{\partial \theta} \right) < 0$$

$$\Leftrightarrow \frac{\partial^2 \ln L(\theta)}{\partial \theta^2} < 0$$

Dengan perkataan lain  $\theta$  juga memaksimumkan  $\ln L(\theta)$ .

( $\leftarrow$ ) karena  $\theta$  memaksimumkan  $\ln L(\theta)$  maka

$$\bullet \quad \frac{\partial \ln L(\theta)}{\partial \theta} = 0,$$

$$\frac{\partial \ln L(\theta)}{\partial \theta} = 0 \Leftrightarrow \frac{1}{L(\theta)} \cdot \frac{\partial L(\theta)}{\partial \theta} = 0 \Leftrightarrow L(\theta) \cdot \frac{1}{L(\theta)} \cdot \frac{\partial L(\theta)}{\partial \theta} = L(\theta) \cdot 0$$

$$\Leftrightarrow \frac{\partial L(\theta)}{\partial \theta} = 0$$

$$\bullet \quad \frac{\partial^2 \ln L(\theta)}{\partial \theta^2} < 0,$$

$$\frac{\partial}{\partial \theta} \left( \frac{1}{L(\theta)} \cdot \frac{\partial L(\theta)}{\partial \theta} \right) < 0 \Leftrightarrow \frac{\partial}{\partial \theta} \left( \frac{1}{L(\theta)} \right) \cdot \frac{\partial L(\theta)}{\partial \theta} + \frac{\partial^2 L(\theta)}{\partial \theta^2} \cdot \frac{1}{L(\theta)} < 0$$

$$\Leftrightarrow \frac{\partial}{\partial \theta} \left( \frac{1}{L(\theta)} \right) \cdot 0 + \frac{\partial^2 L(\theta)}{\partial \theta^2} \cdot \frac{1}{L(\theta)} < 0 \Leftrightarrow \frac{\partial^2 L(\theta)}{\partial \theta^2} \cdot \frac{1}{L(\theta)} < 0$$

$$\Leftrightarrow \frac{\partial^2 L(\theta)}{\partial \theta^2} \cdot \frac{1}{L(\theta)} \cdot L(\theta) < 0 \cdot L(\theta)$$

$$\Leftrightarrow \frac{\partial^2 L(\theta)}{\partial \theta^2} < 0$$

Dengan perkataan lain  $\theta$  juga memaksimumkan  $L(\theta)$ .

Terbukti bahwa  $\theta$  memaksimumkan  $L(\theta) \leftrightarrow \theta$  memaksimumkan  $\ln L(\theta)$ .

## LAMPIRAN 2

Menunjukkan :  $\theta$  memaksimumkan  $L(\theta) \leftrightarrow \theta$  memaksimumkan  $\ln L(\theta)$ ,

$$\theta = (\theta_1, \theta_2, \dots, \theta_n).$$

Bukti:

( $\rightarrow$ ) karena  $\boldsymbol{\theta}$  memaksimumkan  $L(\boldsymbol{\theta})$  maka

- $\frac{\partial L(\boldsymbol{\theta})}{\partial \theta_1} = 0,$
- $\frac{\partial L(\boldsymbol{\theta})}{\partial \theta_2} = 0,$   
 $\vdots$
- $\frac{\partial L(\boldsymbol{\theta})}{\partial \theta_n} = 0,$
- $\frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_i^2} < 0, \quad i = 1, \dots, n,$
- $D = \frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_i^2} \cdot \frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_j^2} - \left( \frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_j \partial \theta_i} \right)^2 > 0, \quad i = 1, \dots, n, \quad j = 1, \dots, n, \quad i \neq j$

akan ditunjukkan  $\boldsymbol{\theta}$  juga memaksimumkan  $\ln L(\boldsymbol{\theta})$  yaitu

$$\bullet \quad \frac{\partial \ln L(\boldsymbol{\theta})}{\partial \theta_1} = 0,$$

$$\frac{\partial \ln L(\boldsymbol{\theta})}{\partial \theta_1} = \frac{1}{L(\boldsymbol{\theta})} \cdot \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_1} = \frac{1}{L(\boldsymbol{\theta})} \cdot 0 = 0$$

$$\therefore \frac{\partial \ln L(\boldsymbol{\theta})}{\partial \theta_1} = 0$$

- $\frac{\partial \ln L(\boldsymbol{\theta})}{\partial \theta_2} = 0$

$$\frac{\partial \ln L(\boldsymbol{\theta})}{\partial \theta_2} = \frac{1}{L(\boldsymbol{\theta})} \cdot \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_2} = \frac{1}{L(\boldsymbol{\theta})} \cdot 0$$

$$\therefore \frac{\partial \ln L(\boldsymbol{\theta})}{\partial \theta_2} = 0$$

⋮

- $\frac{\partial \ln L(\boldsymbol{\theta})}{\partial \theta_n} = 0$

$$\frac{\partial \ln L(\boldsymbol{\theta})}{\partial \theta_n} = \frac{1}{L(\boldsymbol{\theta})} \cdot \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_n} = \frac{1}{L(\boldsymbol{\theta})} \cdot 0$$

$$\therefore \frac{\partial \ln L(\boldsymbol{\theta})}{\partial \theta_n} = 0$$

- $\frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_i^2} < 0 , i = 1, \dots, n$

$$\frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_i^2} = \frac{\partial}{\partial \theta_i} \left( \frac{\partial \ln L(\boldsymbol{\theta})}{\partial \theta_i} \right) = \frac{\partial}{\partial \theta_i} \left( \frac{1}{L(\boldsymbol{\theta})} \cdot \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_i} \right)$$

$$= \frac{\partial}{\partial \theta_i} \left( \frac{1}{L(\boldsymbol{\theta})} \right) \cdot \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_i} + \frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_i^2} \cdot \frac{1}{L(\boldsymbol{\theta})} = \frac{\partial}{\partial \theta_i} \left( \frac{1}{L(\boldsymbol{\theta})} \right) \cdot 0 + \frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_i^2} \cdot \frac{1}{L(\boldsymbol{\theta})}$$

$$= \frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_i^2} \cdot \frac{1}{L(\boldsymbol{\theta})} < 0 \cdot \frac{1}{L(\boldsymbol{\theta})} = 0$$

$$\therefore \frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_i^2} < 0 , i = 1, \dots, n$$

- $D = \frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_i^2} \cdot \frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_j^2} - \left( \frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_j \partial \theta_i} \right)^2 > 0 \quad , i = 1, \dots, n \quad j = 1, \dots, n \quad , i \neq j$

$$\frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_i^2} = \frac{\partial}{\partial \theta_i} \left( \frac{\partial \ln L(\boldsymbol{\theta})}{\partial \theta_i} \right) = \frac{\partial}{\partial \theta_i} \left( \frac{\frac{\partial \ln L(\boldsymbol{\theta})}{\partial \theta_i}}{L(\boldsymbol{\theta})} \right), \quad i = 1, \dots, n$$

$$= \frac{\frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_i^2} \cdot L(\boldsymbol{\theta}) - \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_i} \cdot \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_i}}{L(\boldsymbol{\theta})^2}$$

$$\frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_j^2} = \frac{\partial}{\partial \theta_j} \left( \frac{\partial \ln L(\boldsymbol{\theta})}{\partial \theta_j} \right) = \frac{\partial}{\partial \theta_j} \left( \frac{\frac{\partial \ln L(\boldsymbol{\theta})}{\partial \theta_j}}{L(\boldsymbol{\theta})} \right), \quad j = 1, \dots, n$$

$$= \frac{\frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_j^2} \cdot L(\boldsymbol{\theta}) - \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_j} \cdot \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_j}}{L(\boldsymbol{\theta})^2}$$

$$\frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_i \partial \theta_j} = \frac{\partial}{\partial \theta_j} \left( \frac{\partial \ln L(\boldsymbol{\theta})}{\partial \theta_i} \right) = \frac{\partial}{\partial \theta_j} \left( \frac{\frac{\partial \ln L(\boldsymbol{\theta})}{\partial \theta_i}}{L(\boldsymbol{\theta})} \right), \quad i = 1, \dots, n \quad , j = 1, \dots, n \quad , i \neq j$$

$$= \frac{\frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_j \partial \theta_i} \cdot L(\boldsymbol{\theta}) - \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_j} \cdot \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_i}}{L(\boldsymbol{\theta})^2}$$

$$\begin{aligned}
D &= \left( \frac{\frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_i^2} \cdot L(\boldsymbol{\theta}) - \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_i} \cdot \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_i}}{L(\boldsymbol{\theta})^2} \right) \cdot \left( \frac{\frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_j^2} \cdot L(\boldsymbol{\theta}) - \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_j} \cdot \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_j}}{L(\boldsymbol{\theta})^2} \right) \\
&\quad - \left( \frac{\frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_j \partial \theta_i} \cdot L(\boldsymbol{\theta}) - \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_j} \cdot \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_i}}{L(\boldsymbol{\theta})^2} \right)^2, \quad i = 1, \dots, n, \quad j = 1, \dots, n, \quad i \neq j \\
&= \frac{1}{L(\boldsymbol{\theta})^4} \left[ \frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_i^2} \cdot \frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_j^2} \cdot L(\boldsymbol{\theta})^2 + \left( \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_i} \cdot \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_j} \right)^2 \right. \\
&\quad \left. - \frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_i^2} \cdot \left( \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_j} \right)^2 \cdot L(\boldsymbol{\theta}) - \frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_j^2} \cdot \left( \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_i} \right)^2 \cdot L(\boldsymbol{\theta}) \right] \\
&\quad - \frac{1}{L(\boldsymbol{\theta})^4} \left[ \left( \frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_j \partial \theta_i} \right)^2 \cdot L(\boldsymbol{\theta})^2 + \left( \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_i} \cdot \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_j} \right)^2 \right. \\
&\quad \left. - 2 \left( \frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_j \partial \theta_i} \cdot L(\boldsymbol{\theta}) \cdot \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_j} \cdot \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_i} \right) \right] \\
&= \frac{L(\boldsymbol{\theta})^2}{L(\boldsymbol{\theta})^4} \left[ \frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_i^2} \cdot \frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_j^2} - \left( \frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_j \partial \theta_i} \right)^2 \right] \\
&\quad + \frac{L(\boldsymbol{\theta})}{L(\boldsymbol{\theta})^4} \left[ 2 \cdot \frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_j \partial \theta_i} \cdot \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_j} \cdot \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_i} - \frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_i^2} \cdot \left( \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_j} \right)^2 \right. \\
&\quad \left. - \frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_j^2} \cdot \left( \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_i} \right)^2 \right]
\end{aligned}$$

$$\begin{aligned}
&= \frac{1}{L(\boldsymbol{\theta})^2} \left[ \frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_i^2} \cdot \frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_j^2} - \left( \frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_j \partial \theta_i} \right)^2 \right] + \frac{1}{L(\boldsymbol{\theta})^3} \left[ 2 \cdot \frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_j \partial \theta_i} \cdot 0 \cdot 0 \right. \\
&\quad \left. - \frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_i^2} \cdot (0)^2 - \frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_j^2} \cdot (0)^2 \right] \\
&= \frac{1}{L(\boldsymbol{\theta})^2} \left[ \frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_i^2} \cdot \frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_j^2} - \left( \frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_j \partial \theta_i} \right)^2 \right] > \frac{1}{L(\boldsymbol{\theta})^2} \cdot 0 = 0 \\
\therefore D &= \frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_i^2} \cdot \frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_j^2} - \left( \frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_j \partial \theta_i} \right)^2 > 0 \quad , i = 1, \dots, n \quad , j = 1, \dots, n \quad , i \neq j
\end{aligned}$$

Dengan perkataan lain terbukti bahwa  $\boldsymbol{\theta}$  juga memaksimumkan  $\ln L(\boldsymbol{\theta})$ .

( $\leftarrow$ ) karena  $\boldsymbol{\theta}$  memaksimumkan  $\ln L(\boldsymbol{\theta})$  maka

- $\frac{\partial \ln L(\boldsymbol{\theta})}{\partial \theta_1} = 0$ ,
- $\frac{\partial \ln L(\boldsymbol{\theta})}{\partial \theta_2} = 0$ ,
- $\vdots$
- $\frac{\partial \ln L(\boldsymbol{\theta})}{\partial \theta_n} = 0$
- $\frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_i^2} < 0 \quad , \quad i = 1, \dots, n$ ,
- $D = \frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_i^2} \cdot \frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_j^2} - \left( \frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_j \partial \theta_i} \right)^2 > 0 \quad , \quad i = 1, \dots, n \quad , \quad j = 1, \dots, n \quad , \quad i \neq j$

Akan ditunjukkan  $\theta$  juga memaksimumkan  $L(\theta)$  yaitu:

- $\frac{\partial L(\theta)}{\partial \theta_1} = 0 ,$

$$\frac{\partial L(\theta)}{\partial \theta_1} = L(\theta) \cdot \frac{1}{L(\theta)} \cdot \frac{\partial L(\theta)}{\partial \theta_1} = L(\theta) \cdot \frac{\partial \ln L(\theta)}{\partial \theta_1} = L(\theta) \cdot 0 = 0$$

$$\therefore \frac{\partial L(\theta)}{\partial \theta_1} = 0$$

- $\frac{\partial L(\theta)}{\partial \theta_2} = 0 ,$

$$\frac{\partial L(\theta)}{\partial \theta_2} = L(\theta) \cdot \frac{1}{L(\theta)} \cdot \frac{\partial L(\theta)}{\partial \theta_2} = L(\theta) \cdot \frac{\partial \ln L(\theta)}{\partial \theta_2} = L(\theta) \cdot 0 = 0$$

$$\therefore \frac{\partial L(\theta)}{\partial \theta_2} = 0$$

⋮

- $\frac{\partial L(\theta)}{\partial \theta_n} = 0 ,$

$$\frac{\partial L(\theta)}{\partial \theta_n} = L(\theta) \cdot \frac{1}{L(\theta)} \cdot \frac{\partial L(\theta)}{\partial \theta_n} = L(\theta) \cdot \frac{\partial \ln L(\theta)}{\partial \theta_n} = L(\theta) \cdot 0 = 0$$

$$\therefore \frac{\partial L(\theta)}{\partial \theta_n} = 0$$

- $\frac{\partial^2 L(\theta)}{\partial \theta_i^2} < 0 , \quad i = 1, \dots, n ,$

$$\frac{\partial^2 L(\theta)}{\partial \theta_i^2} = \frac{1}{L(\theta)} \cdot \left[ \frac{\partial^2 \ln L(\theta)}{\partial \theta_i^2} \cdot L(\theta)^2 + \left( \frac{\partial L(\theta)}{\partial \theta_i} \right)^2 \right]$$

$$= \frac{1}{L(\boldsymbol{\theta})} \cdot \left[ \frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_i^2} \cdot L(\boldsymbol{\theta})^2 + 0 \right]$$

$$= \frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_i^2} \cdot L(\boldsymbol{\theta}) < 0 \cdot L(\boldsymbol{\theta}) = 0$$

$$\therefore \frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_i^2} < 0, \quad i = 1, \dots, n$$

•  $D = \frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_i^2} \cdot \frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_j^2} - \left( \frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_j \partial \theta_i} \right)^2 > 0, \quad i = 1, \dots, n, \quad j = 1, \dots, n, \quad i \neq j$

$$\frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_i^2} = \frac{\frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_i^2} \cdot L(\boldsymbol{\theta})^2 + \left( \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_i} \right)^2}{L(\boldsymbol{\theta})}, \quad i = 1, \dots, n$$

$$\frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_j^2} = \frac{\frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_j^2} \cdot L(\boldsymbol{\theta})^2 + \left( \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_j} \right)^2}{L(\boldsymbol{\theta})}, \quad j = 1, \dots, n$$

$$\frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_j \partial \theta_i} = \frac{\frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_j \partial \theta_i} \cdot L(\boldsymbol{\theta})^2 + \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_j} \cdot \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_i}}{L(\boldsymbol{\theta})}, \quad i = 1, \dots, n, \quad j = 1, \dots, n, \quad i \neq j$$

$$D = \left( \frac{\frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_i^2} \cdot L(\boldsymbol{\theta})^2 + \left( \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_i} \right)^2}{L(\boldsymbol{\theta})} \right) \cdot \left( \frac{\frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_j^2} \cdot L(\boldsymbol{\theta})^2 + \left( \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_j} \right)^2}{L(\boldsymbol{\theta})} \right)$$

$$- \left( \frac{\frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_j \partial \theta_i} \cdot L(\boldsymbol{\theta})^2 + \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_j} \cdot \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_i}}{L(\boldsymbol{\theta})} \right)^2, \quad i = 1, \dots, n, \quad j = 1, \dots, n, \quad i \neq j$$

$$\begin{aligned}
&= \frac{1}{L(\boldsymbol{\theta})^2} \left[ \frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_i^2} \cdot \frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_j^2} \cdot L(\boldsymbol{\theta})^4 + \left( \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_i} \cdot \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_j} \right)^2 \right. \\
&\quad \left. + \frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_i^2} \cdot \left( \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_j} \right)^2 \cdot L(\boldsymbol{\theta})^2 + \frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_j^2} \cdot \left( \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_i} \right)^2 \cdot L(\boldsymbol{\theta})^2 \right] \\
&\quad - \frac{1}{L(\boldsymbol{\theta})^2} \left[ \left( \frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_j \partial \theta_i} \right)^2 \cdot L(\boldsymbol{\theta})^4 + \left( \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_i} \cdot \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_j} \right)^2 \right. \\
&\quad \left. + 2 \left( \frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_j \partial \theta_i} \cdot L(\boldsymbol{\theta})^2 \cdot \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_j} \cdot \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_i} \right) \right] \\
&= \frac{L(\boldsymbol{\theta})^4}{L(\boldsymbol{\theta})^2} \left[ \frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_i^2} \cdot \frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_j^2} - \left( \frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_j \partial \theta_i} \right)^2 \right] \\
&\quad + \frac{L(\boldsymbol{\theta})^2}{L(\boldsymbol{\theta})^2} \left[ \frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_i^2} \cdot \left( \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_j} \right)^2 + \frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_j^2} \cdot \left( \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_i} \right)^2 \right. \\
&\quad \left. - 2 \cdot \frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_j \partial \theta_i} \cdot \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_j} \cdot \frac{\partial L(\boldsymbol{\theta})}{\partial \theta_i} \right] \\
&= L(\boldsymbol{\theta})^2 \left[ \frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_i^2} \cdot \frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_j^2} - \left( \frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_j \partial \theta_i} \right)^2 \right] + 1 \cdot \left[ \frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_i^2} \cdot (0)^2 + \right. \\
&\quad \left. \frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_j^2} \cdot (0)^2 - 2 \cdot \frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_j \partial \theta_i} \cdot 0 \cdot 0 \right] \\
&= L(\boldsymbol{\theta})^2 \left[ \frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_i^2} \cdot \frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_j^2} - \left( \frac{\partial^2 \ln L(\boldsymbol{\theta})}{\partial \theta_j \partial \theta_i} \right)^2 \right] > L(\boldsymbol{\theta})^2 \cdot 0 = 0
\end{aligned}$$

$$\therefore D = \frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_i^2} \cdot \frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_j^2} - \left( \frac{\partial^2 L(\boldsymbol{\theta})}{\partial \theta_j \partial \theta_i} \right)^2 > 0 , \quad i=1,\dots,n , \quad j=1,\dots,n , \quad i \neq j$$

Dengan perkataan lain terbukti bahwa  $\boldsymbol{\theta}$  juga memaksimumkan  $L(\boldsymbol{\theta})$ .

Terbukti bahwa  $\boldsymbol{\theta}$  memaksimumkan  $L(\boldsymbol{\theta}) \Leftrightarrow \boldsymbol{\theta}$  memaksimumkan  $\ln L(\boldsymbol{\theta})$ ,

$$\boldsymbol{\theta} = (\theta_1, \theta_2, \dots, \theta_n).$$

### LAMPIRAN 3

#### Metode Newton Raphson

Misalkan  $\boldsymbol{\xi}$  adalah vektor dari  $2k$  buah parameter yang tidak diketahui, yaitu

$\boldsymbol{\xi} = (\xi_1, \dots, \xi_j), \quad \xi_j = (a_j, b_j), \quad j=1, \dots, k, \quad I(\boldsymbol{\xi})$  adalah fungsi *log – likelihood* dari vektor  $\boldsymbol{\xi}$ ,  $\mathbf{f}'[\boldsymbol{\xi}]$  adalah vektor turunan parsial pertama dari  $I(\boldsymbol{\xi})$  yaitu

$$\mathbf{f}'(\boldsymbol{\xi}) = \begin{bmatrix} \mathbf{f}'_{a_j}[\boldsymbol{\xi}] \\ \mathbf{f}'_{b_j}[\boldsymbol{\xi}] \end{bmatrix} = \begin{bmatrix} \frac{\partial I(\boldsymbol{\xi})}{\partial a_j} \\ \frac{\partial I(\boldsymbol{\xi})}{\partial b_j} \end{bmatrix}, \text{ dan } \mathbf{H}(\boldsymbol{\xi}) \text{ adalah matriks turunan parsial kedua dari } I(\boldsymbol{\xi}) \text{ yaitu}$$

$$\mathbf{H}(\boldsymbol{\xi}) = \begin{bmatrix} \frac{\partial \mathbf{f}'(\boldsymbol{\xi})}{\partial a_j} & \frac{\partial \mathbf{f}'(\boldsymbol{\xi})}{\partial b_j} \end{bmatrix}$$

$$= \begin{bmatrix} \frac{\partial \mathbf{f}'_{a_j}[\boldsymbol{\xi}]}{\partial a_j} & \frac{\partial \mathbf{f}'_{a_j}[\boldsymbol{\xi}]}{\partial b_j} \\ \frac{\partial \mathbf{f}'_{b_j}[\boldsymbol{\xi}]}{\partial a_j} & \frac{\partial \mathbf{f}'_{b_j}[\boldsymbol{\xi}]}{\partial b_j} \end{bmatrix}$$

$$= \begin{bmatrix} \frac{\partial^2 I(\boldsymbol{\xi})}{\partial \mathbf{a}_j^2} & \frac{\partial^2 I(\boldsymbol{\xi})}{\partial b_j \partial \mathbf{a}_j} \\ \frac{\partial^2 I(\boldsymbol{\xi})}{\partial \mathbf{a}_j \partial b_j} & \frac{\partial^2 I(\boldsymbol{\xi})}{\partial b_j^2} \end{bmatrix}$$

$$= \begin{bmatrix} H_{a_j a_j}(\boldsymbol{\xi}) & H_{a_j b_j}(\boldsymbol{\xi}) \\ H_{b_j a_j}(\boldsymbol{\xi}) & H_{b_j b_j}(\boldsymbol{\xi}) \end{bmatrix}$$

Dengan menggunakan metode Newton Raphson akan dicari taksiran dari  $\boldsymbol{\xi}$  yang merupakan penyelesaian dari  $\mathbf{f}'(\boldsymbol{\xi}) = 0$ . Jika diberikan taksiran awal dari  $\boldsymbol{\xi}$ , yaitu  $\hat{\boldsymbol{\xi}}^{(0)}$ , maka dapat diperoleh pendekatan deret Taylor orde pertama dari vektor  $\mathbf{f}'(\boldsymbol{\xi})$  disekitar  $\boldsymbol{\xi} = \hat{\boldsymbol{\xi}}^{(0)}$ , yaitu:

$$\begin{aligned} \mathbf{f}'(\boldsymbol{\xi}) &\approx \mathbf{f}'(\hat{\boldsymbol{\xi}}^{(0)}) + \left. \frac{\partial \mathbf{f}'(\boldsymbol{\xi})}{\partial \mathbf{a}_j} \right|_{\boldsymbol{\xi}=\hat{\boldsymbol{\xi}}^{(0)}} (\mathbf{a}_j - \hat{\mathbf{a}}_j^{(0)}) + \left. \frac{\partial \mathbf{f}'(\boldsymbol{\xi})}{\partial b_j} \right|_{\boldsymbol{\xi}=\hat{\boldsymbol{\xi}}^{(0)}} (b_j - \hat{b}_j^{(0)}) \\ &\approx \mathbf{f}'(\hat{\boldsymbol{\xi}}^{(0)}) + \begin{bmatrix} \left. \frac{\partial \mathbf{f}'(\boldsymbol{\xi})}{\partial \mathbf{a}_j} \right|_{\boldsymbol{\xi}=\hat{\boldsymbol{\xi}}^{(0)}} & \left. \frac{\partial \mathbf{f}'(\boldsymbol{\xi})}{\partial b_j} \right|_{\boldsymbol{\xi}=\hat{\boldsymbol{\xi}}^{(0)}} \end{bmatrix} \begin{bmatrix} \mathbf{a}_j - \hat{\mathbf{a}}_j^{(0)} \\ b_j - \hat{b}_j^{(0)} \end{bmatrix} \\ &\approx \mathbf{f}'(\hat{\boldsymbol{\xi}}^{(0)}) + \begin{bmatrix} \frac{\partial^2 I(\boldsymbol{\xi})}{\partial \mathbf{a}_j^2} & \frac{\partial^2 I(\boldsymbol{\xi})}{\partial b_j \partial \mathbf{a}_j} \\ \frac{\partial^2 I(\boldsymbol{\xi})}{\partial \mathbf{a}_j \partial b_j} & \frac{\partial^2 I(\boldsymbol{\xi})}{\partial b_j^2} \end{bmatrix}_{\boldsymbol{\xi}=\hat{\boldsymbol{\xi}}^{(0)}} (\boldsymbol{\xi} - \hat{\boldsymbol{\xi}}^{(0)}) \\ &\approx \mathbf{f}'(\hat{\boldsymbol{\xi}}^{(0)}) + \begin{bmatrix} H_{a_j a_j}(\boldsymbol{\xi}) & H_{b_j a_j}(\boldsymbol{\xi}) \\ H_{a_j b_j}(\boldsymbol{\xi}) & H_{b_j b_j}(\boldsymbol{\xi}) \end{bmatrix}_{\boldsymbol{\xi}=\hat{\boldsymbol{\xi}}^{(0)}} (\boldsymbol{\xi} - \hat{\boldsymbol{\xi}}^{(0)}) \end{aligned}$$

Atau:

$$\mathbf{f}'(\boldsymbol{\xi}) \approx \mathbf{f}'(\hat{\boldsymbol{\xi}}^{(0)}) + \mathbf{H}(\hat{\boldsymbol{\xi}}^{(0)}) (\boldsymbol{\xi} - \hat{\boldsymbol{\xi}}^{(0)}) \quad (1)$$

dengan :

$\mathbf{f}'(\hat{\boldsymbol{\xi}}^{(0)})$  adalah vektor turunan parsial pertama dari  $I(\boldsymbol{\xi})$  dihitung pada

$$\boldsymbol{\xi} = \hat{\boldsymbol{\xi}}^{(0)}.$$

$\mathbf{H}(\hat{\boldsymbol{\xi}}^{(0)})$  adalah matriks turunan parsial kedua dari  $I(\boldsymbol{\xi})$  dihitung pada  $\boldsymbol{\xi} = \hat{\boldsymbol{\xi}}^{(0)}$ .

Karena ingin mencari penyelesaian dari  $\mathbf{f}'(\boldsymbol{\xi})=0$ , maka dapat ditulis:

$$\begin{aligned} 0 &= \mathbf{f}'(\boldsymbol{\xi}) \approx \mathbf{f}'(\hat{\boldsymbol{\xi}}^{(0)}) + \mathbf{H}(\hat{\boldsymbol{\xi}}^{(0)}) (\boldsymbol{\xi} - \hat{\boldsymbol{\xi}}^{(0)}) \\ \mathbf{H}(\hat{\boldsymbol{\xi}}^{(0)}) (\boldsymbol{\xi} - \hat{\boldsymbol{\xi}}^{(0)}) &= -\mathbf{f}'(\hat{\boldsymbol{\xi}}^{(0)}) \end{aligned} \quad (2)$$

Jika matriks  $\mathbf{H}(\hat{\boldsymbol{\xi}}^{(0)})$  tidak singular maka:

$$\begin{aligned} [\mathbf{H}(\hat{\boldsymbol{\xi}}^{(0)})]^{-1} \mathbf{H}(\hat{\boldsymbol{\xi}}^{(0)}) (\boldsymbol{\xi} - \hat{\boldsymbol{\xi}}^{(0)}) &= -[\mathbf{H}(\hat{\boldsymbol{\xi}}^{(0)})]^{-1} \mathbf{f}'(\hat{\boldsymbol{\xi}}^{(0)}) \\ (\boldsymbol{\xi} - \hat{\boldsymbol{\xi}}^{(0)}) &= -[\mathbf{H}(\hat{\boldsymbol{\xi}}^{(0)})]^{-1} \mathbf{f}'(\hat{\boldsymbol{\xi}}^{(0)}) \\ \boldsymbol{\xi} &= \hat{\boldsymbol{\xi}}^{(0)} - [\mathbf{H}(\hat{\boldsymbol{\xi}}^{(0)})]^{-1} \mathbf{f}'(\hat{\boldsymbol{\xi}}^{(0)}) \end{aligned} \quad (3)$$

Nilai  $\boldsymbol{\xi}$  menjadi taksiran baru yang kemudian dinotasikan dengan  $\hat{\boldsymbol{\xi}}^{(1)}$ :

$$\hat{\boldsymbol{\xi}}^{(1)} = \hat{\boldsymbol{\xi}}^{(0)} - [\mathbf{H}(\hat{\boldsymbol{\xi}}^{(0)})]^{-1} \mathbf{f}'(\hat{\boldsymbol{\xi}}^{(0)}) \quad (4)$$

Jika  $\hat{\boldsymbol{\xi}}^{(1)} \approx \hat{\boldsymbol{\xi}}^{(0)}$  (misalkan  $\|\hat{\boldsymbol{\xi}}^{(m+1)} - \hat{\boldsymbol{\xi}}^{(m)}\| < 10^{-5}$ ), maka hentikan proses iterasi

dan kemudian ambil  $\hat{\boldsymbol{\xi}}^{(1)}$  sebagai taksiran dari  $\hat{\boldsymbol{\xi}}$ . Sebaliknya, lanjutkan

iterasi. Jika diberikan taksiran  $\hat{\xi}^{(1)}$  maka dapat diperoleh pendekatan deret

Taylor orde pertama dari vektor  $\mathbf{f}'(\xi)$  sekitar  $\xi = \hat{\xi}^{(1)}$ , yaitu :

$$\mathbf{f}'(\xi) \approx \mathbf{f}'(\hat{\xi}^{(1)}) + \mathbf{H}(\hat{\xi}^{(1)})(\xi - \hat{\xi}^{(1)}) \quad (5)$$

dengan:

$\mathbf{f}'(\hat{\xi}^{(1)})$  adalah vektor turunan parsial pertama dari  $I(\xi)$  dihitung pada  $\xi = \hat{\xi}^{(1)}$ ,

$\mathbf{H}(\hat{\xi}^{(1)})$  adalah matriks turunan parsial kedua dari  $I(\xi)$  dihitung pada  $\xi = \hat{\xi}^{(1)}$ .

Dengan menyelesaikan

$$0 = \mathbf{f}'(\xi) \approx \mathbf{f}'(\hat{\xi}^{(1)}) + \mathbf{H}(\hat{\xi}^{(1)})(\xi - \hat{\xi}^{(1)})$$

diperoleh

$$\mathbf{H}(\hat{\xi}^{(1)})(\xi - \hat{\xi}^{(1)}) = -\mathbf{f}'(\hat{\xi}^{(1)}) \quad (6)$$

Jika matriks  $\mathbf{H}(\hat{\xi}^{(1)})$  tidak singular maka :

$$\begin{aligned} [\mathbf{H}(\hat{\xi}^{(1)})]^{-1} \mathbf{H}(\hat{\xi}^{(1)})(\xi - \hat{\xi}^{(1)}) &= -[\mathbf{H}(\hat{\xi}^{(1)})]^{-1} \mathbf{f}'(\hat{\xi}^{(1)}) \\ (\xi - \hat{\xi}^{(1)}) &= -[\mathbf{H}(\hat{\xi}^{(1)})]^{-1} \mathbf{f}'(\hat{\xi}^{(1)}) \\ \xi &= \hat{\xi}^{(1)} - [\mathbf{H}(\hat{\xi}^{(1)})]^{-1} \mathbf{f}'(\hat{\xi}^{(1)}) \end{aligned} \quad (7)$$

Nilai  $\xi$  menjadi taksiran baru yang kemudian dinotasikan dengan  $\hat{\xi}^{(2)}$ :

$$\hat{\xi}^{(2)} = \hat{\xi}^{(1)} - [\mathbf{H}(\hat{\xi}^{(1)})]^{-1} \mathbf{f}'(\hat{\xi}^{(1)}) \quad (8)$$

Dengan mengulang langkah yang sama dapat diperoleh taksiran  $\hat{\xi}^{(3)}, \hat{\xi}^{(4)}$ , dan seterusnya. Secara umum dapat ditentukan taksiran dari  $\xi$  pada iterasi ke  $-m+1$ , yaitu  $\hat{\xi}^{(m+1)}$ , secara iteratif menggunakan formula:

$$\hat{\xi}^{(m+1)} = \hat{\xi}^{(m)} - [H(\hat{\xi}^{(m)})]^{-1} f'(\hat{\xi}^{(m)}), \quad m = 0, 1, \dots \quad (9)$$

dengan:

$f'(\hat{\xi}^{(m)})$  adalah vektor turunan parsial pertama dari  $I(\xi)$  dihitung pada

$$\xi = \hat{\xi}^{(m)},$$

$H(\hat{\xi}^{(m)})$  adalah matriks turunan parsial kedua dari  $I(\xi)$  dihitung pada

$$\xi = \hat{\xi}^{(m)}.$$

Hentikan proses iterasi jika  $\hat{\xi}^{(m+1)} \approx \hat{\xi}^{(m)}$  (misalkan  $\|\hat{\xi}^{(m+1)} - \hat{\xi}^{(m)}\| < 10^{-5}$ ), lalu ambil  $\hat{\xi}^{(m+1)}$  sebagai taksiran dari  $\hat{\xi}$ .

#### Lampiran 4

Menunjukkan  $\Delta = \left\{ \left( \frac{\partial^2 I(\xi)}{\partial a_j^2} \right) \left( \frac{\partial^2 I(\xi)}{\partial b_j^2} \right) - \left( \frac{\partial^2 I(\xi)}{\partial a_j \partial b_j} \right)^2 \right\} > 0$  dan  $\left( \frac{\partial^2 I(\xi)}{\partial a_j^2} \right) < 0$

atau  $\left( \frac{\partial^2 I(\xi)}{\partial b_j^2} \right) < 0$ .

Diketahui turunan parsial kedua dari  $I(\xi)$  terhadap  $a_j$  dan  $b_j$  adalah:

$$\frac{\partial^2 I(\boldsymbol{\xi})}{\partial \mathbf{a}_j^2} = -\sum_{i=1}^n \left\{ \theta_i^2 \cdot \left( \frac{e^{a_j \theta_i - b_j}}{1 + e^{a_j \theta_i - b_j}} \right) \cdot \left( \frac{1}{1 + e^{a_j \theta_i - b_j}} \right) \right\} = -\sum_{i=1}^n \{ \theta_i^2 \cdot p_{ij} \cdot q_{ij} \} < 0$$

untuk setiap  $a_j$  dan  $b_j$ ,

$$\frac{\partial^2 I(\boldsymbol{\xi})}{\partial \mathbf{a}_j \partial \mathbf{b}_j} = \sum_{i=1}^n \left\{ \theta_i \cdot \left( \frac{e^{a_j \theta_i - b_j}}{1 + e^{a_j \theta_i - b_j}} \right) \cdot \left( \frac{1}{1 + e^{a_j \theta_i - b_j}} \right) \right\} = \sum_{i=1}^n \{ \theta_i \cdot p_{ij} \cdot q_{ij} \},$$

$$\frac{\partial^2 I(\boldsymbol{\xi})}{\partial \mathbf{b}_j^2} = -\sum_{i=1}^n \left\{ \left( \frac{e^{a_j \theta_i - b_j}}{1 + e^{a_j \theta_i - b_j}} \right) \cdot \left( \frac{1}{1 + e^{a_j \theta_i - b_j}} \right) \right\} = -\sum_{i=1}^n \{ p_{ij} \cdot q_{ij} \} < 0$$

untuk setiap  $a_j$  dan  $b_j$ , dengan

$$p_{ij} = \left( \frac{e^{a_j \theta_i - b_j}}{1 + e^{a_j \theta_i - b_j}} \right) \text{ dan } q_{ij} = 1 - p_{ij} = \left( 1 - \frac{e^{a_j \theta_i - b_j}}{1 + e^{a_j \theta_i - b_j}} \right) = \left( \frac{1}{1 + e^{a_j \theta_i - b_j}} \right).$$

Oleh karena itu, untuk setiap  $a_j$  dan  $b_j$  diperoleh :

$$\begin{aligned} \Delta &= \left\{ \left( \frac{\partial^2 I(\boldsymbol{\xi})}{\partial \mathbf{a}_j^2} \right) \left( \frac{\partial^2 I(\boldsymbol{\xi})}{\partial \mathbf{b}_j^2} \right) - \left( \frac{\partial^2 I(\boldsymbol{\xi})}{\partial \mathbf{a}_j \partial \mathbf{b}_j} \right)^2 \right\} \\ &= \left\{ \left( -\sum_{i=1}^n \{ \theta_i^2 \cdot p_{ij} \cdot q_{ij} \} \right) \left( -\sum_{i=1}^n \{ p_{ij} \cdot q_{ij} \} \right) - \left( \sum_{i=1}^n \{ \theta_i \cdot p_{ij} \cdot q_{ij} \} \right)^2 \right\} \\ &= \left\{ \left( \sum_{i=1}^n \{ \theta_i^2 \cdot p_{ij} \cdot q_{ij} \} \right) \left( \sum_{i=1}^n \{ p_{ij} \cdot q_{ij} \} \right) - \left( \sum_{i=1}^n \{ \theta_i \cdot p_{ij} \cdot q_{ij} \} \right)^2 \right\} \\ &= \left\{ (\theta_1^2 \cdot p_{1j} \cdot q_{1j} + \theta_2^2 \cdot p_{2j} \cdot q_{2j} + \dots + \theta_n^2 \cdot p_{nj} \cdot q_{nj}) (p_{1j} \cdot q_{1j} + p_{2j} \cdot q_{2j} + \dots + p_{nj} \cdot q_{nj}) - \right. \\ &\quad \left. (\theta_1 \cdot p_{1j} \cdot q_{1j} + \theta_2 \cdot p_{2j} \cdot q_{2j} + \dots + \theta_n \cdot p_{nj} \cdot q_{nj})^2 \right\} \\ &= \left\{ (\theta_1^2 \cdot p_{1j}^2 \cdot q_{1j}^2 + \theta_1^2 \cdot p_{1j} \cdot p_{2j} \cdot q_{1j} \cdot q_{2j} + \dots + \theta_1^2 \cdot p_{1j} \cdot p_{nj} \cdot q_{1j} \cdot q_{nj} + \theta_2^2 \cdot p_{1j} \cdot p_{2j} \cdot q_{1j} \cdot q_{2j} + \right. \\ &\quad \theta_2^2 \cdot p_{2j}^2 \cdot q_{2j}^2 + \dots + \theta_2^2 \cdot p_{2j} \cdot p_{nj} \cdot q_{2j} \cdot q_{nj} + \dots + \theta_n^2 \cdot p_{1j} \cdot p_{nj} \cdot q_{1j} \cdot q_{nj} + \\ &\quad \left. \theta_n^2 \cdot p_{2j} \cdot p_{nj} \cdot q_{2j} \cdot q_{nj} + \dots + \theta_n^2 \cdot p_{nj}^2 \cdot q_{nj}^2) - (\theta_1^2 \cdot p_{1j}^2 \cdot q_{1j}^2 + \theta_2 \cdot \theta_1 \cdot p_{1j} \cdot p_{2j} \cdot q_{1j} \cdot q_{2j} + \right. \\ &\quad \left. \dots + \theta_n \cdot \theta_1 \cdot p_{1j} \cdot p_{nj} \cdot q_{1j} \cdot q_{nj} + \dots + \theta_n \cdot \theta_2 \cdot p_{2j} \cdot p_{nj} \cdot q_{2j} \cdot q_{nj}) \right\} \end{aligned}$$

$$\begin{aligned}
& \dots + \theta_n \cdot \theta_1 \cdot p_{1j} \cdot p_{nj} \cdot q_{1j} \cdot q_{nj} + \theta_1 \cdot \theta_2 \cdot p_{1j} \cdot p_{2j} \cdot q_{1j} \cdot q_{2j} + \theta_2^2 \cdot p_{2j}^2 \cdot q_{2j}^2 + \dots + \\
& \theta_n \cdot \theta_2 \cdot p_{2j} \cdot p_{nj} \cdot q_{2j} \cdot q_{nj} + \dots + \theta_1 \cdot \theta_2 \cdot p_{1j} \cdot p_{nj} \cdot q_{1j} \cdot q_{nj} + \theta_2 \cdot \theta_n \cdot p_{2j} \cdot p_{nj} \cdot q_{2j} \cdot q_{nj} + \dots + \\
& \theta_n^2 \cdot p_{nj}^2 \cdot q_{nj}^2 \Big) \Big\} \\
= & \left\{ (\theta_1^2 - 2\theta_1 \cdot \theta_2 + \theta_2^2) p_{1j} \cdot p_{2j} \cdot q_{1j} \cdot q_{2j} + \dots + (\theta_1^2 - 2\theta_1 \cdot \theta_n + \theta_n^2) p_{1j} \cdot p_{nj} \cdot q_{1j} \cdot q_{nj} + \right. \\
& \left. (\theta_2^2 - 2\theta_2 \cdot \theta_n + \theta_n^2) p_{2j} \cdot p_{nj} \cdot q_{2j} \cdot q_{nj} + \dots \right\} \\
= & \left\{ (\theta_1 - \theta_2)^2 p_{1j} \cdot p_{2j} \cdot q_{1j} \cdot q_{2j} + \dots + (\theta_1 - \theta_n)^2 p_{1j} \cdot p_{nj} \cdot q_{1j} \cdot q_{nj} + \right. \\
& \left. (\theta_2 - \theta_n)^2 p_{2j} \cdot p_{nj} \cdot q_{2j} \cdot q_{nj} + \dots \right\} > 0
\end{aligned}$$

## Lampiran 5

Data jawaban tes Matematika siswa kelas VII SMP XYZ

Peserta	Jawaban
1	1 1 1 1 1 1 1 1 1 0 1 1 1 1 0 1 0 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1
2	1 0 0 1 0 1 1 0 0 1 0 1 0 0 0 1 0 1 1 0 1 1 0 0 0 0 1 1 1 0
3	0 0 0 1 0 0 1 1 0 0 0 0 1 0 0 0 1 1 0 0 1 1 1 1 0 1 0 1 0 0
4	1 1 0 1 1 1 0 1 1 0 1 0 1 1 1 1 1 0 1 1 1 1 1 1 0 0 1 1 0 0
5	1 0 1 0 1 1 1 1 0 1 1 1 1 1 0 0 1 1 0 1 1 1 1 1 1 0 0 0 1 1
6	1 1 1 0 0 0 1 0 1 0 0 1 1 1 1 0 1 1 1 1 1 1 0 0 1 0 1 0 0 0
7	1 0 1 1 0 1 0 1 1 0 1 1 1 1 1 1 1 1 1 0 1 1 1 1 0 1 1 1 0 1
8	1 1 0 0 1 1 0 0 1 0 0 1 0 1 0 0 1 0 1 0 1 0 1 0 1 1 0 0 1 0 0
9	1 0 0 0 1 1 1 1 1 1 0 0 1 1 0 1 1 1 1 1 1 1 1 0 0 0 0 1 0
10	1 1 0 1 0 1 0 1 1 1 1 1 1 1 0 0 1 0 1 0 1 0 1 0 1 0 0 0 1 0 1
11	1 0 0 0 0 0 0 0 0 0 1 0 1 0 0 1 1 1 1 1 1 1 1 1 0 1 0 0 0
12	1 1 1 0 1 1 1 1 1 1 1 1 1 1 0 1 1 1 1 1 1 1 1 1 1 1 1 1 0 1
13	1 1 0 1 1 1 1 0 1 1 1 1 0 1 0 0 1 1 1 0 1 1 0 1 1 1 1 1 0
14	1 1 1 1 1 1 1 1 1 1 1 0 1 0 0 1 1 1 0 1 1 1 1 0 1 1 1 1 0
15	1 0 0 0 1 1 0 0 1 0 0 0 0 1 0 0 0 1 1 0 1 1 0 1 1 1 1 0 0
16	1 1 1 0 1 1 1 1 1 1 1 1 1 0 0 1 1 0 1 1 0 1 1 0 1 1 0 1 1 0

17	000011011000010011111101001010
18	11000111111110101110110111010
19	101011011001010101101101001101
20	11111111111111111111111101111111
21	100011011111110010101101010010
22	010110011001011001001100100010
23	11010101101011111111111100100
24	11000000101000000001110100100
25	110010101110010000101101101001
26	11111111110011011001101101111
27	100101001001010011000100010000
28	100001011011000011001111000000
29	111111111011011011111110101000
30	110111111010011110101110110100
31	110011000001010010011111111011
32	111111111111111111111111000111
33	010001011001011010001110100110
34	100001011011010000101101100100
35	10000100100101001010101101100110
36	100001011011010101011101010110
37	1111111111110110111100111101111
38	101100101111010011111101101111
39	000101000001010001101100111010
40	000000101110110101111100100011
41	000001000001011000001110110000
42	011000101110110011110010000000
43	110100001001010000101010000010
44	110100001000010000001100010100
45	101010000001000010100100100010
46	11110111111011011100111111101
47	111101100001011011110110111100
48	101001011001010011110010110000
49	000100001001000110010010010000
50	0001000110010100111011110000010
51	11110011101100011111100010100
52	100000000000010001001111000100
53	100010111110010111110111111110
54	110111100111110101111101011111
55	101101111110110111111101111111

56	100101001111011111100101111111
57	010111101111011011111111011111
58	100011101111011111101101000110
59	01010100101111101010011111101
60	10101000010001101010100000001110
61	10010101000101101010101101111010
62	100010000001110010111110110000
63	000001011000001010010010100000
64	100000001101010010101011010110
65	101001101101011101001100111100
66	000010011100010100001001000010
67	000101111010100001101011010010
68	11001100101101000010111111010
69	000000001101110011111010001100
70	100001011001000010101110101000
71	101001010000010000001110011000
72	1000011011111100001111110111111
73	10111111111111011111101111111
74	000101001010010011101111101110
75	100101010000011000110100101110
76	101101100011111100001101011000
77	110001011111011111011111111101
78	100001111001111011111111110100
79	100111011011010011101101010100
80	10110101011101001010101101111000
81	1000110111100110001010111100000
82	101101001001010010100000100000
83	001001001011110010101001100100
84	000101010010010000010111111110
85	0110011010111110111100111110101
86	10100100101001001010101100100101
87	100101111011010011111111101100
88	10000100000101101001011101011001
89	0001010000110100101101001111110
90	1000011010001110010011101100000
91	111111111111100111111011111111
92	000000010001010100101100010000
93	100011000010111001111111101010
94	1101011111101111101101101010

95	101100010111010000000000001110
96	100001011111010101001111101100
97	10010100111111011101110100111
98	110000000001011011111100101000
99	000001000001000010101110000000
100	101011010111010001001001001011000
101	1001111011101110101100111101110
102	00100110100111000010111010100000
103	10100101100110101010101100101100
104	10111000010001001010101010100000
105	100111110111010110001010010111
106	10010100100001001110110010101000
107	100101011111011101101101101101101
108	101111011011010101001111001100
109	10110111111101101111011011111111
110	000101010011010000110101001100
111	100001011001110001101100100011
112	10111111011011111111111111111111
113	1011111111110111111101111111110
114	1000011011010100101101100000000
115	100101001101010011111111110100
116	0000010110010110001011001111101
117	11111111111111001101101111011111
118	10000110101001001010101000111000
119	100001111111111111111111110110111
120	1000010110110101111101101111101
121	1111111111111100111111011011111
122	100001000101000100011111001010
123	1000000011111010001011100001000
124	100001101001000001101000011000
125	101111111111011011101111110111
126	100111000101101000111110000010
127	1010110110100110101111011111100
128	0010000000000110001011101000000
129	000000000000010001000010101000
130	111101000100010011100100110110
131	110001110000010001101110011110
132	101111111110110111101001101111
133	00000011111110011110111001000

134	000000000100000010011001001010
135	100111000011010001110100111111
136	11111111111101111111101101111
137	100000100001100010101111001000
138	10000101111101011111101001110
139	110010011101010110101111001110
140	111001101001110001101100111110
141	1101010111110100011101110111100
142	111101111110110111100101111111
143	1011111111011110111111111111

