

BAB III

LATENT CLASS MODEL

3.1 MODEL

Latent class model adalah suatu model matematika yang menghubungkan probabilitas respon suatu individu untuk K variabel indikator kategorik, dengan suatu variabel laten X yang bersifat kategorik dengan M kelas. Misalkan Y_1, Y_2, \dots, Y_K adalah variabel indikator yang merupakan variabel biner.

Suatu individu akan memberikan jawaban (respon) untuk setiap variabel indikator. Misal y_{ki} adalah respon individu ke- i terhadap variabel indikator Y_k , $i = 1, 2, \dots, n$; $k = 1, 2, \dots, K$. Sebut $\tilde{y}_i = (y_{1i}, y_{2i}, \dots, y_{Ki})$ adalah respon individu ke- i untuk K variabel indikator.

Dimana:

$y_{ki} = 1$; jika individu i memberi jawaban "iya" untuk variabel indikator Y_k , $k = 1, 2, \dots, K$
 $y_{ki} = 0$; jika individu i memberi jawaban "tidak" untuk variabel indikator Y_k , $k = 1, 2, \dots, K$

Sebut:

$$\Pr(\tilde{Y}_i = \tilde{y}_i) = \Pr(Y_{1i} = y_{1i}, Y_{2i} = y_{2i}, \dots, Y_{Ki} = y_{Ki})$$

= probabilitas suatu individu memberikan respon y_{1i} untuk

variabel Y_{1i} , y_{2i} untuk variabel Y_{2i} , ..., y_{Ki} untuk variabel Y_{Ki} .

$$\Pr(\tilde{Y}_i = \tilde{y}_i | X = m) = \Pr(Y_{1i} = y_{1i}, Y_{2i} = y_{2i}, \dots, Y_{Ki} = y_{Ki} | X = m)$$

= probabilitas suatu individu memberikan respon y_{1i} untuk

variabel Y_{1i} , y_{2i} untuk variabel Y_{2i} , ..., y_{Ki} untuk variabel Y_{Ki} ,

jika diketahui individu tersebut berada pada *latent class* ke- m

dari variabel laten X .

$$\Pr(\tilde{Y}_i = \tilde{y}_i, X = m) = \Pr(Y_{1i} = y_{1i}, Y_{2i} = y_{2i}, \dots, Y_{Ki} = y_{Ki}, X = m)$$

= probabilitas suatu individu i memberikan respon y_{1i} untuk

variabel Y_{1i} , y_{2i} untuk variabel Y_{2i} , ..., y_{Ki} untuk variabel Y_{Ki} ,

dan berada pada kelas laten ke- m dari variabel laten X .

$$\pi_m = \Pr(X = m)$$

= probabilitas suatu individu berada pada kelas ke- m dari

variabel laten X ; $m = 1, 2, \dots$

$$= \frac{\text{banyaknya individu di kelas ke-}m}{\text{banyak individu seluruhnya}}$$

$$P_{k|m} = \Pr(Y_{ki} = y_{ki} | X = m)$$

= probabilitas menjawab "iya" untuk variable indicator Y_k , jika

diketahui individu tersebut berada di kelas ke- m dari variable

laten X

$$= \frac{\text{banyaknya individu di kelas ke-}m \text{ yang menjawab "iya" untuk } Y_k}{\text{banyak individu di kelas ke-}m}$$

$Y_{k|m}$, $k = 1, 2, \dots, K$ adalah respon individu i untuk variabel indikator Y_k , jika diketahui individu tersebut berada di kelas ke- m dari variabel laten X .

$Y_{k|m}$ berdistribusi binomial $(1, P_{k|m})$.

$$\Pr(Y_{ki} = y_{ki} | X = m) = P_{k|m}^{y_{ki}} (1 - P_{k|m})^{1 - y_{ki}}$$

$k = 1, 2, \dots, K$.

Maka probabilitas suatu individu yang berada pada kelas ke- m dari variabel laten X memberikan respon \tilde{y}_i dapat didefinisikan sebagai:

$$\begin{aligned} \Pr(\tilde{Y}_i = \tilde{y}_i | X = m) &= \Pr(Y_{1i} = y_{1i}, Y_{2i} = y_{2i}, \dots, Y_{Ki} = y_{Ki} | X = m) \\ &= \prod_{k=1}^K P_{k|m}^{y_{ki}} (1 - P_{k|m})^{1 - y_{ki}} \end{aligned} \quad (3.1.1)$$

Karena variabel-variabel $Y_{1i}, Y_{2i}, \dots, Y_{Ki}$, dan X merupakan variabel kategorik, maka $\Pr(Y_{1i} = y_{1i}, Y_{2i} = y_{2i}, \dots, Y_{Ki} = y_{Ki}, X = m)$ merupakan pdf bersama untuk $Y_{1i}, Y_{2i}, \dots, Y_{Ki}, X$; $\Pr(Y_{1i} = y_{1i}, Y_{2i} = y_{2i}, \dots, Y_{Ki} = y_{Ki})$ merupakan pdf bersama dari variabel $Y_{1i}, Y_{2i}, \dots, Y_{Ki}$ atau pdf marginal dari variabel $Y_{1i}, Y_{2i}, \dots, Y_{Ki}$, dan X . Jadi,

$$\begin{aligned} \Pr(Y_{1i} = y_{1i}, Y_{2i} = y_{2i}, \dots, Y_{Ki} = y_{Ki}) &= \sum_{m=1}^M \Pr(Y_{1i} = y_{1i}, Y_{2i} = y_{2i}, \dots, Y_{Ki} = y_{Ki}, X = m) \\ &= \sum_{m=1}^M \Pr(\tilde{Y}_i = \tilde{y}_i, X = m) \end{aligned} \quad (3.1.2)$$

Dengan mensubstitusikan persamaan (3.1.1), didapatkan:

$$\begin{aligned}\Pr(\tilde{Y}_i = \tilde{y}_i, X = m) &= \Pr(X = m)\Pr(\tilde{Y}_i = \tilde{y}_i | X = m) \\ &= \pi_m \prod_{k=1}^K P_{k|m}^{y_{ki}} (1 - P_{k|m})^{1-y_{ki}}\end{aligned}\quad (3.1.3)$$

Dengan mensubstitusikan persamaan (3.1.3) ke persamaan (3.1.2), maka dapat $\Pr(Y_{1i} = y_{1i}, Y_{2i} = y_{2i}, \dots, Y_{Ki} = y_{Ki})$ dituliskan sebagai:

$$\begin{aligned}\Pr(Y_{1i} = y_{1i}, Y_{2i} = y_{2i}, \dots, Y_{Ki} = y_{Ki}) &= \sum_{m=1}^M \Pr(\tilde{Y}_i = \tilde{y}_i, X = m) \\ &= \sum_{m=1}^M \pi_m \Pr(\tilde{Y}_i = \tilde{y}_i | X = m) \\ &= \sum_{m=1}^M \pi_m \prod_{k=1}^K P_{k|m}^{y_{ki}} (1 - P_{k|m})^{1-y_{ki}}\end{aligned}$$

Notasikan persamaan diatas dengan $\Pi_{\tilde{y}_i}$

$$\Pi_{\tilde{y}_i} = \sum_{m=1}^M \pi_m \prod_{k=1}^K P_{k|m}^{y_{ki}} (1 - P_{k|m})^{1-y_{ki}} \quad (3.1.4)$$

Persamaan di atas disebut *latent class model*.

Jadi, *latent class model* merepresentasikan probabilitas bersama dari variabel-variabel Y_1, Y_2, \dots, Y_K , dalam bentuk parameter-parameter *latent class*, π_m dan $p_{k|m}$.

Selanjutnya, notasikan:

$$\begin{aligned}\Pi_{m|\tilde{\mathbf{y}}_i} &= \Pr(X = m | (\tilde{\mathbf{Y}}_i = \tilde{\mathbf{y}}_i)) \\ &= \Pr(X = m | Y_{1i} = y_{1i}, Y_{2i} = y_{2i}, \dots, Y_{Ki} = y_{Ki})\end{aligned}\quad (3.1.5)$$

sebagai probabilitas bersyarat suatu individu akan berada pada kelas ke- m dari variabel laten X , jika diketahui individu tersebut memberikan respon $(y_{1i}, y_{2i}, \dots, y_{Ki})$ untuk variabel indikator $(Y_{1i}, Y_{2i}, \dots, Y_{Ki})$.

Dengan menggunakan teorema bayes, persamaan (3.1.5) menjadi:

$$\begin{aligned}\Pi_{m|\tilde{\mathbf{y}}_i} &= \frac{\Pr(X = m) \Pr(Y_{1i} = y_{1i}, Y_{2i} = y_{2i}, \dots, Y_{Ki} = y_{Ki} | X = m)}{\sum_{s=1}^M \Pr(X = s) \Pr(Y_{1i} = y_{1i}, Y_{2i} = y_{2i}, \dots, Y_{Ki} = y_{Ki} | X = s)} \\ &= \frac{\pi_m \prod_{k=1}^K P_{k|m}^{y_{ki}} (1 - P_{k|m})^{1-y_{ki}}}{\sum_{s=1}^M \pi_s \prod_{k=1}^K P_{k|s}^{y_{ki}} (1 - P_{k|s})^{1-y_{ki}}}\end{aligned}\quad (3.1.6)$$

Klasifikasi suatu individu pada kelas-kelas dari variabel laten X akan ditetapkan berdasarkan nilai probabilitas $\Pi_{m|\tilde{\mathbf{y}}_i}$ untuk setiap kelas- m dari individu tersebut. Kelas ke- m yang memberikan nilai terbesar untuk $\Pi_{m|\tilde{\mathbf{y}}_i}$ akan menjadi kelas dari variabel latent X untuk individu i tersebut yang memberikan jawaban $\tilde{\mathbf{y}}_i$.

3.2 PENAKSIRAN PARAMETER DALAM MODEL

Salah satu metode yang dapat digunakan untuk menaksir nilai parameter-parameter dalam *latent class model* adalah metode maksimum likelihood. Misalkan terdapat n individu yang diobservasi, maka didapatkan fungsi likelihood untuk *latent class model* adalah sebagai berikut:

$$L(\boldsymbol{\pi}, \mathbf{P}) = \prod_{i=1}^n \left[\sum_{m=1}^M \pi_m \prod_{k=1}^K P_{k|m}^{y_{ki}} (1 - P_{k|m})^{1-y_{ki}} \right] \quad (3.2.1)$$

dimana $\tilde{\mathbf{y}}_i = (y_{1i}, y_{2i}, \dots, y_{Ki})$, $\boldsymbol{\pi} = (\pi_1, \pi_2, \dots, \pi_M)$; $\mathbf{P} = (P_{11}, \dots, P_{KM})$.

Akan dicari nilai untuk π_m dan P_{km} ; $m = 1, 2, \dots, M$ dan $k = 1, 2, \dots, K$ yang memaksimumkan $L(\boldsymbol{\pi}, \mathbf{P})$. Untuk mempermudah perhitungan, $L(\boldsymbol{\pi}, \mathbf{P})$ dapat dimodifikasi menjadi:

$$\begin{aligned} l = \ln(L(\boldsymbol{\pi}, \mathbf{P})) &= \ln \left\{ \prod_{i=1}^n \left[\sum_{m=1}^M \pi_m \prod_{k=1}^K P_{k|m}^{y_{ki}} (1 - P_{k|m})^{1-y_{ki}} \right] \right\} \\ &= \sum_{i=1}^n \ln \left[\sum_{m=1}^M \pi_m \prod_{k=1}^K P_{k|m}^{y_{ki}} (1 - P_{k|m})^{1-y_{ki}} \right] \end{aligned} \quad (3.2.2)$$

Maka,

$$\frac{\partial l}{\partial \pi_m} = \sum_{i=1}^n \frac{\prod_{k=1}^K P_{k|m}^{y_{ki}} (1 - P_{k|m})^{1-y_{ki}}}{\sum_{s=1}^M \pi_s \prod_{j=1}^K P_{j|s}^{y_{ji}} (1 - P_{j|s})^{1-y_{ji}}}$$

untuk $m = 1, 2, \dots, M$.

dan

$$\frac{\partial l}{\partial P_{km}} = \sum_{i=1}^n \left\{ \frac{\left[y_{ki} P_{k|m}^{y_{ki}-1} (1-P_{k|m})^{1-y_{ki}} - (1-y_{ki})(1-P_{k|m})^{-y_{ki}} P_{k|m}^{y_{ki}} \right] \left[\pi_m \prod_{\substack{j=1 \\ j \neq k}}^K P_{j|m}^{y_{ji}} (1-P_{j|m})^{1-y_{ji}} \right]}{\sum_{s=1}^M \pi_s \prod_{j=1}^K P_{j|s}^{y_{ji}} (1-P_{j|s})^{1-y_{ji}}} \right\}$$

Untuk $k = 1, 2, \dots, K$.

Taksiran maksimum likelihood dari 3.2.1 sulit diselesaikan secara analitis dan memuat variable laten X . Oleh karena itu akan digunakan algoritma EM (*Expectation-Maximization*) untuk memperoleh taksiran dari parameter-parameter pada *latent class model*.

Algoritma EM adalah suatu proses iteratif untuk menghitung taksiran maksimum likelihood yang dilakukan dengan 2 tahap, tahapan *E-step* dan *M-step*.

a) *E-step* (langkah ekspektasi)

Seperti telah dijelaskan dalam BAB II, dalam *E-step* akan dicari

$$E \left[\log [p(x, y, \theta_t)] \mid y, \hat{\theta}_{t-1} \right] = \sum_x \log p(x, y, \theta_t) p(x \mid y, \hat{\theta}_{t-1}).$$

Dalam *latent class model*, tahapan *E-step* dilakukan untuk mencari ekspektasi dari

$$\log \left(\prod_{i=1}^n \Pr(\tilde{Y}_i = \tilde{y}_i, X = m) \right)$$

untuk setiap kelas- m dari variabel laten X , dengan

diberikan data terobservasi Y_i dan nilai asumsi untuk π_m dan $P_{k|m}$,

$m = 1, 2, \dots, M; k = 1, 2, \dots, K$.

Berdasarkan persamaan (3.1.3), $\log\left(\prod_{i=1}^n \Pr(\tilde{Y}_i = \tilde{y}_i, X = m)\right)$ dapat

dituliskan sebagai berikut:

$$\log\left(\prod_{i=1}^n \Pr(\tilde{Y}_i = \tilde{y}_i, X = m)\right) = \log\left(\prod_{i=1}^n \left[\pi_m \prod_{k=1}^K P_{k|m}^{y_{ki}} (1 - P_{k|m})^{1-y_{ki}}\right]\right)$$

E-step dilakukan dengan mencari

$$E\left[\log\left(\prod_{i=1}^n \left[\pi_m^{(t)} \prod_{k=1}^K P_{k|m}^{(t) y_{ki}} (1 - P_{k|m}^{(t)})^{1-y_{ki}}\right]\right) \middle| y_i, \hat{\pi}_m^{(t-1)}, \hat{P}_{k|m}^{(t-1)}\right]$$

dimana:

$\pi_m^{(t)}$ adalah nilai π_m pada iterasi ke-t

$P_{k|m}^{(t)}$ adalah nilai $P_{k|m}$ pada iterasi ke-t

$$\begin{aligned} & E\left(\log\left(\prod_{i=1}^n \Pr(\tilde{Y}_i = \tilde{y}_i, X = m)\right) \middle| y_i, \hat{\pi}_m^{(t-1)}, \hat{P}_{k|m}^{(t-1)}\right) \\ &= \sum_{m=1}^M \log\left(\prod_{i=1}^n \Pr(\tilde{Y}_i = \tilde{y}_i, X = m)\right) \Pr(\tilde{y}_i, x \mid \tilde{y}_i, \hat{\pi}_m^{(t-1)}, \hat{P}_{k|m}^{(t-1)}) \\ &= \sum_{m=1}^M \sum_{i=1}^n \log(\Pr(\tilde{Y}_i = \tilde{y}_i, X = m)) \Pr(x \mid y_i, \hat{\pi}_m^{(t-1)}, \hat{P}_{k|m}^{(t-1)}) \\ &= \sum_{m=1}^M \sum_{i=1}^n \log(\Pr(\tilde{Y}_i = \tilde{y}_i, X = m)) \Pi_{m \mid y_i, \hat{\pi}_m^{(t-1)}, \hat{P}_{k|m}^{(t-1)}} \\ &= \sum_{m=1}^M \sum_{i=1}^n \log\left(\pi_m^{(t)} \prod_{k=1}^K P_{k|m}^{(t) y_{ki}} (1 - P_{k|m}^{(t)})^{1-y_{ki}}\right) \left(\frac{\hat{\pi}_m^{(t-1)} \prod_{k=1}^K \hat{P}_{k|m}^{(t-1) y_{ki}} (1 - \hat{P}_{k|m}^{(t-1)})^{1-y_{ki}}}{\sum_{m=1}^M \hat{\pi}_m^{(t-1)} \prod_{k=1}^K \hat{P}_{k|m}^{(t-1) y_{ki}} (1 - \hat{P}_{k|m}^{(t-1)})^{1-y_{ki}}} \right) \end{aligned}$$

$t = 1, 2, \dots$

b) M-step (langkah maksimisasi)

Setelah melakukan E-step, langkah selanjutnya dengan melakukan M-step, dimana pada proses ini akan dicari nilai taksiran untuk $\pi_m^{(t)}$ dan $P_{k|m}^{(t)}$ yang memaksimumkan

$$E \left(\log \left(\prod_{i=1}^n \Pr(\tilde{Y}_i = \tilde{y}_i, X = m) \right) \middle| \tilde{\mathbf{y}}_i, \hat{\pi}_m^{(t-1)}, \hat{P}_{k|m}^{(t-1)} \right)$$

$$= \sum_{m=1}^M \sum_{i=1}^n \log \left(\pi_m^{(t)} \prod_{k=1}^K P_{k|m}^{(t) y_{ki}} (1 - P_{k|m}^{(t)})^{1-y_{ki}} \right) \left(\frac{\hat{\pi}_m^{(t-1)} \prod_{k=1}^K \hat{P}_{k|m}^{(t-1) y_{ki}} (1 - \hat{P}_{k|m}^{(t-1)})^{1-y_{ki}}}{\sum_{m=1}^M \hat{\pi}_m^{(t-1)} \prod_{k=1}^K \hat{P}_{k|m}^{(t-1) y_{ki}} (1 - \hat{P}_{k|m}^{(t-1)})^{1-y_{ki}}} \right)$$

yang didapat pada E-step.

Proses E-step dan M-step ini akan dilakukan terus secara iteratif sampai didapatkan suatu taksiran untuk π_m dan P_{km} yang konvergen atau didapatkan $\left| \hat{\pi}_m^{(t)} - \hat{\pi}_m^{(t-1)} \right|$ dan $\left| \hat{P}_{km}^{(t)} - \hat{P}_{km}^{(t-1)} \right|$, $k = 1, 2, \dots, K$; $m = 1, 2, \dots, M$, yang cukup kecil.

3.3 UJI KECOCOKAN MODEL

Dalam pembentukan suatu model diperlukan uji kecocokan model.

Dalam pembentukan *latent class model*, uji kecocokan model dilakukan untuk setiap banyak kelas $M \geq 1$, kemudian menentukan banyak kelas optimal yang memberikan model yang cocok. Uji kecocokan model pada tugas akhir ini akan dilakukan dengan uji rasio likelihood.

Akan diuji hipotesis sebagai berikut:

H_0 : Model cocok untuk suatu M tertentu ; $M = 1, 2, 3, \dots$

H_1 : tidak demikian.

Pada pengujian hipotesis tersebut, ingin dilihat, apakah

$\hat{\Pi}_{\tilde{y}_i} = P_{\tilde{y}_i}$; untuk $\tilde{y}_i = \tilde{y}_i$.

$\hat{\Pi}_{\tilde{y}_i}$ adalah taksiran dari model dan $P_{\tilde{y}_i}$ didapat dari data.

$$\hat{\Pi}_{\tilde{y}_i} = \sum_{m=1}^M \hat{\pi}_m \prod_{k=1}^K \hat{P}_{k|m}^{y_{ki}} (1 - \hat{P}_{k|m})^{1-y_{ki}}$$

$$P_{\tilde{y}_i} = \frac{\text{banyak individu yang memberi jawaban } \tilde{y}_i}{\text{banyak individu seluruhnya}} = \frac{f_{\tilde{y}_i}}{n}$$

Definisikan fungsi likelihood sebagai berikut:

$$\bullet L_0 = \prod_{i=1}^n \left[\sum_{m=1}^M \hat{\pi}_m \prod_{k=1}^K \hat{P}_{k|m}^{y_{ki}} (1 - \hat{P}_{k|m})^{1-y_{ki}} \right] = \prod_{i=1}^n [\hat{\Pi}_{\tilde{y}_i}]$$

Setiap individu i akan memberikan jawaban (respon) untuk setiap variabel indikator. Karena terdapat K variabel indikator biner, maka akan ada 2^K kemungkinan jawaban dari suatu individu, yaitu

$(0,0,\dots,0),\dots,(1,1,\dots,1)$. Notasikan dengan \tilde{y}_i . Dan $f_{\tilde{y}_i}$ adalah banyaknya individu yang memberi respon \tilde{y}_i . Oleh karena itu L_0 dapat dituliskan menjadi:

$$\begin{aligned}
 L_0 &= \prod_{i=1}^n \left[\sum_{m=1}^M \hat{\pi}_m \prod_{k=1}^K \hat{p}_{k|m}^{y_{ki}} (1 - \hat{p}_{k|m})^{1-y_{ki}} \right] \\
 &= \prod_{i=1}^n [\hat{\Pi}_{\tilde{y}_i}] \\
 &= \prod_{\tilde{y}_i=(0,0,\dots,0)}^{(1,1,\dots,1)} [\hat{\Pi}_{\tilde{y}_i}]^{f_{\tilde{y}_i}} \\
 &= \prod_{\tilde{y}_i=(0,0,\dots,0)}^{(1,1,\dots,1)} [\hat{\Pi}_{\tilde{y}_i}]^{n \cdot P_{\tilde{y}_i}} \\
 \bullet \quad L_1 &= \prod_{\tilde{y}_i=(0,0,\dots,0)}^{(1,1,\dots,1)} \left(\frac{f_{\tilde{y}_i}}{n} \right)^{f_{\tilde{y}_i}} \\
 &= \prod_{\tilde{y}_i=(0,0,\dots,0)}^{(1,1,\dots,1)} (P_{\tilde{y}_i})^{f_{\tilde{y}_i}} = \prod_{\tilde{y}_i=(0,0,\dots,0)}^{(1,1,\dots,1)} (P_{\tilde{y}_i})^{n \cdot P_{\tilde{y}_i}}
 \end{aligned}$$

Pandang :

$$\begin{aligned}
 \lambda &= \frac{L_0}{L_1} \\
 &= \frac{\prod_{\tilde{y}_i=(0,0,\dots,0)}^{(1,1,\dots,1)} [\hat{\Pi}_{\tilde{y}_i}]^{n \cdot P_{\tilde{y}_i}}}{\prod_{\tilde{y}_i=(0,0,\dots,0)}^{(1,1,\dots,1)} (P_{\tilde{y}_i})^{n \cdot P_{\tilde{y}_i}}} \\
 &= \prod_{\tilde{y}_i=(0,0,\dots,0)}^{(1,1,\dots,1)} \frac{[\hat{\Pi}_{\tilde{y}_i}]^{n \cdot P_{\tilde{y}_i}}}{(P_{\tilde{y}_i})^{n \cdot P_{\tilde{y}_i}}} = \prod_{\tilde{y}_i=(0,0,\dots,0)}^{(1,1,\dots,1)} \left[\frac{\hat{\Pi}_{\tilde{y}_i}}{P_{\tilde{y}_i}} \right]^{n \cdot P_{\tilde{y}_i}}
 \end{aligned}$$

Statistik uji yang digunakan dalam uji kecocokan *latent class model* yaitu

$$\begin{aligned}
 L^2 &= -2 \ln \lambda = -2 \ln \left[\prod_{\tilde{y}_i=(0,0,\dots,0)}^{(1,1,\dots,1)} \left[\frac{\hat{\Pi}_{\tilde{y}_i}}{P_{\tilde{y}_i}} \right]^{n \cdot P_{\tilde{y}_i}} \right] \\
 &= 2 \ln \left[\prod_{\tilde{y}_i=(0,0,\dots,0)}^{(1,1,\dots,1)} \left[\frac{\hat{\Pi}_{\tilde{y}_i}}{P_{\tilde{y}_i}} \right]^{n \cdot P_{\tilde{y}_i}} \right]^{-1} \\
 &= 2 \ln \left[\prod_{\tilde{y}_i=(0,0,\dots,0)}^{(1,1,\dots,1)} \left[\frac{P_{\tilde{y}_i}}{\hat{\Pi}_{\tilde{y}_i}} \right]^{n \cdot P_{\tilde{y}_i}} \right] \\
 &= 2 \sum_{\tilde{y}_i=(0,0,\dots,0)}^{(1,1,\dots,1)} \ln \left[\frac{P_{\tilde{y}_i}}{\hat{\Pi}_{\tilde{y}_i}} \right]^{n \cdot P_{\tilde{y}_i}} \\
 &= 2n \sum_{\tilde{y}_i=(0,0,\dots,0)}^{(1,1,\dots,1)} P_{\tilde{y}_i} \ln \left[\frac{P_{\tilde{y}_i}}{\hat{\Pi}_{\tilde{y}_i}} \right]
 \end{aligned}$$

L^2 akan berdistribusi χ^2_r , dimana $r = 2^K - 1 - (M - 1 + MK)$. H_0 akan ditolak jika $L^2 > \chi^2_r$.

Pada kasus dimana $P_{(y_i)} = \hat{\Pi}_{(y_i)}$, untuk setiap y_i ; $y_i = (0,0,\dots,0), \dots,$

$(1,1,\dots,1)$ kecocokan model dianggap sempurna dan L^2 akan bernilai 0.

Pada kasus $L^2 > 0$, L^2 menghitung kekurangan cocokan model. Jadi, dapat disimpulkan bahwa L^2 semakin kecil (L^2 mendekati 0), model semakin cocok.

Untuk memilih *latent class model* terbaik, diantara yang cocok, atau dengan kata lain menentukan banyak kelas optimal yang cukup menjelaskan hubungan diantara variabel-variabel indikatornya adalah dengan melihat

%reduksi dari L^2 . %reduksi L^2 dihitung dengan menganggap model dengan $M=1$ sebagai *baseline* (M_0), dan membandingkan $L^2(M_0)$ dengan L^2 yang didapat untuk $M > 1$.

$$\%reduksi L^2 = \frac{L^2(M_0) - L^2(M_{(M-1)})}{L^2(M_0)} \times 100\%; \quad m = 2, 3, \dots$$

Model yang dipilih adalah model dengan banyak kelas M , dimana terdapat perbedaan nilai % reduksi L^2 model dengan banyak kelas M dengan nilai % reduksi L^2 model dengan banyak kelas $(M - 1)$ cukup signifikan.

