

پس در این ساختار انتخاب بیاورد دو پارامتر نیاز داریم و ساختار ما برش واریانس کواریانس متحقق نمی باشد.

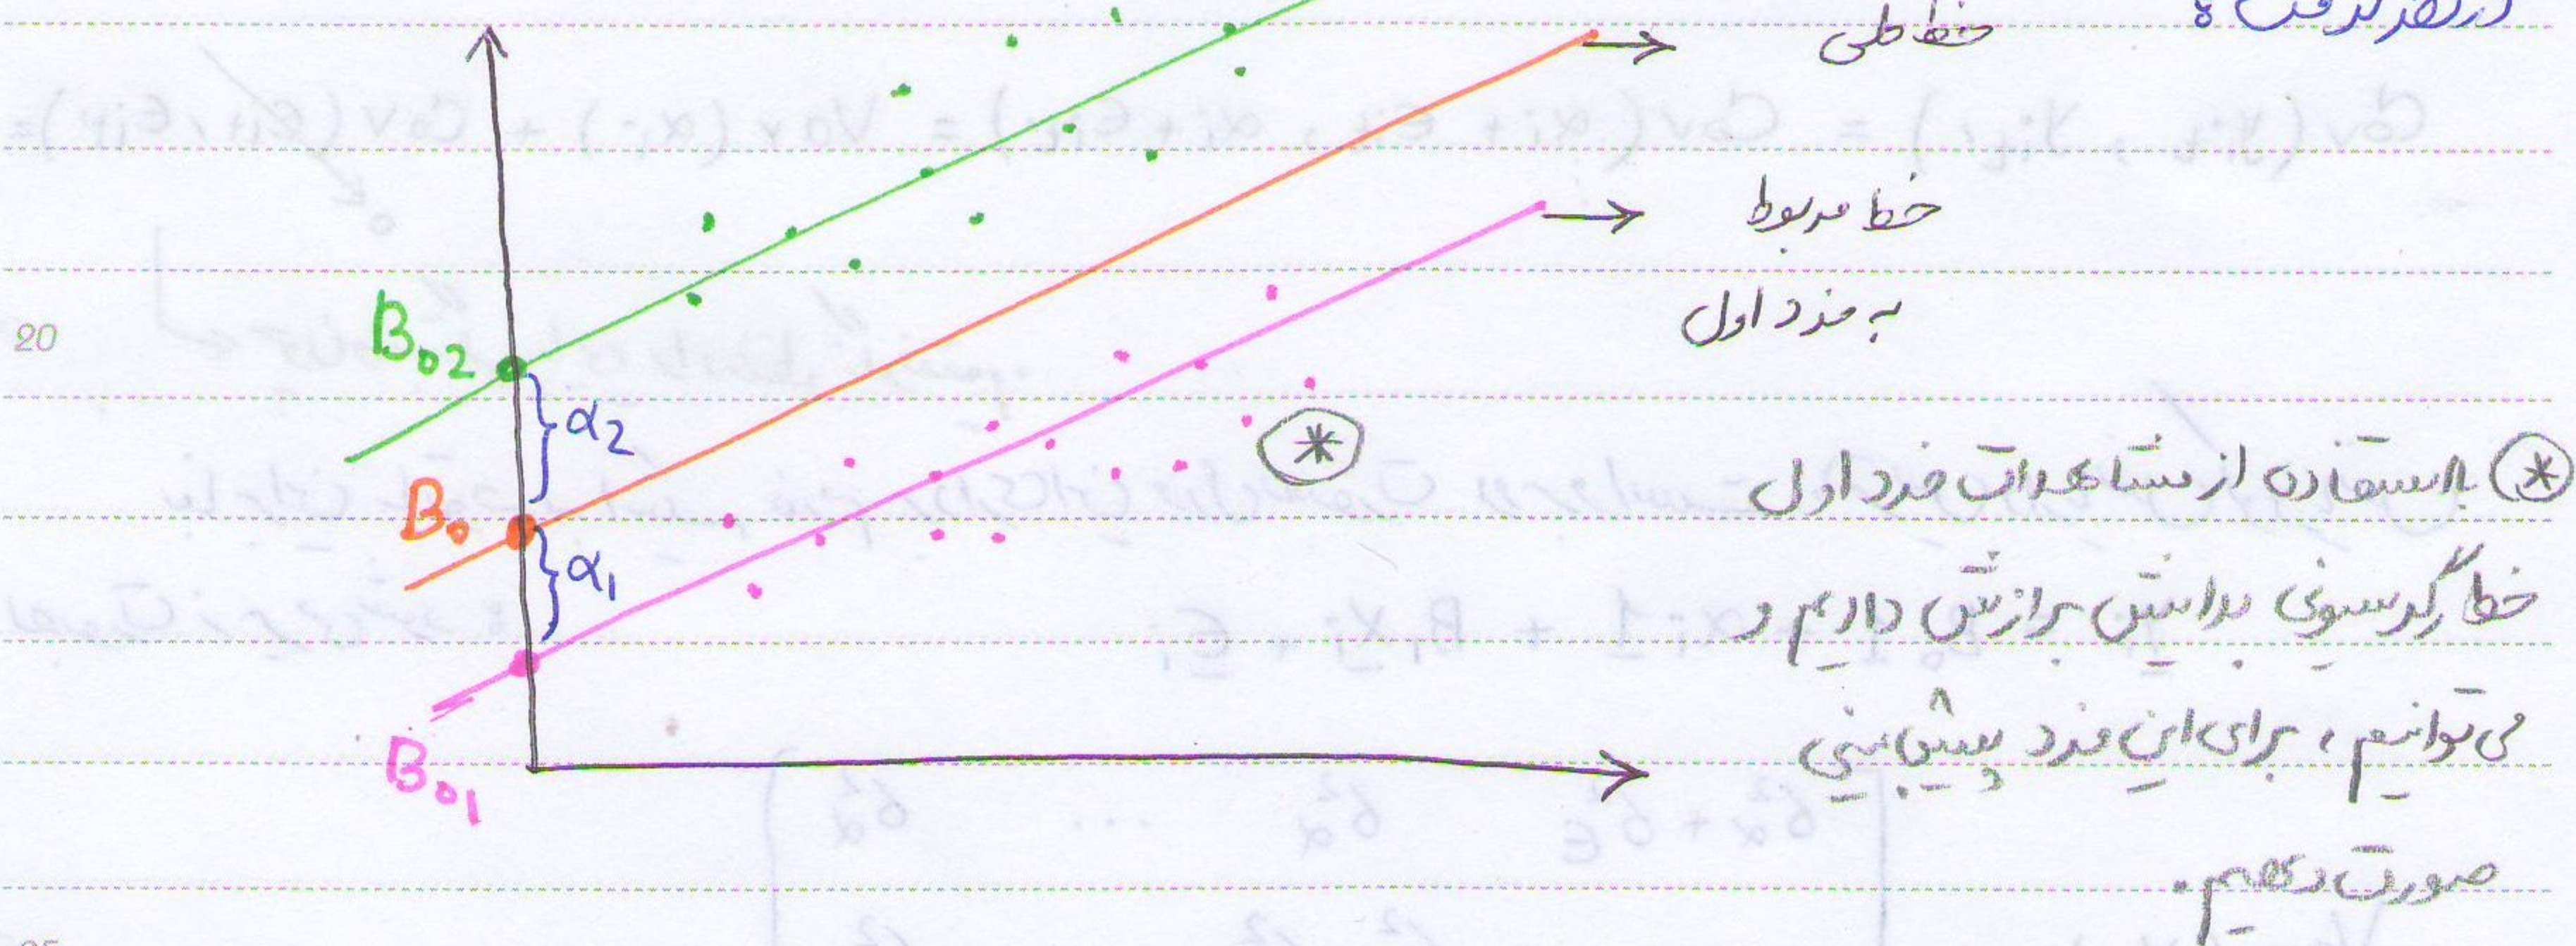
* رقت داشته باشیم که این ساختار را برش داریم واریانس کواریانس است که ما در نظر گرفتیم (جنون مثال وابستگی درون گروهی داریم). پس باید داده ها را بررسی نمود تا بفهمیم که آیا این ساختار برای داده ها درست است یا خیر و مسأله $mispice\ Fraction$ وجود نیاید. چون باعث می شود برآورد دقای OLS ، $BLUE$ نشوند. بعنوان مثال این مدل برای داده های پانلی خوب است ولی برای داده های طولی که وابستگی پانلی دارند مناسب نمی باشد.

به این مدل $random\ intercept\ model$ می گویند و به صورت زیر آن را نمایش می دهند:

$$Y_{it} = B_{0i} + \beta_1 X_{it} + \epsilon_{it}$$

$B_{0i} + \alpha_i$ مقدار اختلاف
 با عرض از مبدأ کلی
 برای فرد i

در این حالت هر فرد برای خود یک خط رگرسیونی جدا دارد که می توان پیش بینی را طبق این خط برای آن فرد در نظر گرفت.



خطوط رگرسیونی برای افراد مختلف دارای شیب یکسان و عرض از مبدأ متفاوت می باشند.

* مقدار α_i هم مانند ϵ_i برآورد می شود، B_0 و B_1 را هم به دست می آوریم، پس با این صورت مقدار عرض از صبراً برای هر فرد برآورد می شود و می توان خطاگر سری مربوط به آن فرد را رسم کرد.

* با استفاده از خط کپی می توان برای فرد جدید اضافه شده به نمونه، پس بانی صورت دار.

2- حالت دوم.

این بار علاوه بر α_i ، $b_i x_{it}$ (که اثر تصادفی است) را نیز وارد مدل می کنیم. (روایح اینبار علاوه بر عرض از صبراً، شیب مدل هم تصادفی می شود).

$$y_{it} = B_{0i} + B_{1i} x_{it} + \epsilon_{it}$$

$\underbrace{B_{0i} + \alpha_i}_{\text{عرض از صبراً کلی مدل}} \quad \underbrace{B_{1i} + b_i}_{\text{شیب کلی مدل}} \rightarrow \begin{cases} \epsilon_{it} \stackrel{iid}{\sim} N(0, \sigma_{\epsilon}^2) \\ \begin{pmatrix} \alpha_i \\ b_i \end{pmatrix} \stackrel{*}{\sim} N_2(0, \Sigma) \end{cases}$

$\Sigma = \begin{bmatrix} \sigma_{\alpha}^2 & \sigma_{\alpha b} \\ \sigma_{\alpha b} & \sigma_b^2 \end{bmatrix}$

$$y_{it} = B_0 + B_1 x_{it} + \alpha_i + b_i x_{it} + \epsilon_{it}$$

$\underbrace{\alpha_i + b_i x_{it}}_{u_{it}} \leftarrow \text{که قبلاً گفتیم نا همبسته اند.}$

* α_i و b_i ها و ϵ_i هم وابسته اند، چون عوامل مربوط به فرد i ام هستند، بنابراین بنشینان کنارشان همبسته و توزیع را با هم می گیریم.

$$y_i = [1 \quad x_i] \begin{bmatrix} B_0 \\ B_1 \end{bmatrix} + [1 \quad x_i] \begin{bmatrix} \alpha_i \\ b_i \end{bmatrix} + \epsilon_i$$



همانطور که از اینها می بینیم به تغییر توضیحی در نظر گرفتیم.

$$y_i = z_i \beta + z_i \delta_i + \epsilon_i$$

حال ساختار ماتریس واریانس کواریانس را بدست می آوریم:

$$\begin{aligned} \text{Var}(\underline{y}_i) &= \text{Var}(\underline{z}_i \underline{\delta}_i + \underline{\epsilon}_i') = \underline{z}_i \text{Var}(\underline{\delta}_i) \underline{z}_i' + \text{Var}(\underline{\epsilon}_i') = \\ &= \underline{z}_i \Sigma \underline{z}_i' + \sigma_{\epsilon}^2 \mathbf{I} \end{aligned}$$

5

البته اگر خواهیم درایه های ماتریس را بصورت دقیق بدست آوریم، داریم:

$$\text{Var}(y_{it}) = \text{Var}(\alpha_i + b_i x_{it} + \epsilon_{it}') = \text{Var}(\alpha_i) + x_{it}^2 \text{Var}(b_i)$$

$$+ \text{Var}(\epsilon_{it}') + 2x_{it} \text{Cov}(\alpha_i, b_i) = \sigma_{\alpha}^2 + x_{it}^2 \sigma_b^2 + \sigma_{\epsilon}^2 + 2x_{it} \sigma_{\alpha b}$$

$$^{1/2} \text{Cov}(y_{it}, y_{it'}) = \text{Cov}(\alpha_i + b_i x_{it} + \epsilon_{it}', \alpha_i + b_i x_{it'} + \epsilon_{it'}) =$$

چون وابستگی یابی نداریم.

$$^{15} = \text{Var}(\alpha_i) + x_{it} x_{it'} \text{Var}(b_i) + \text{Cov}(\epsilon_{it'}, \epsilon_{it}) + x_{it'} \text{Cov}(\alpha_i, b_i)$$

$$+ \text{Cov}(\alpha_i, \epsilon_{it'}) + x_{it} \text{Cov}(\alpha_i, b_i) + x_{it} \text{Cov}(b_i, \epsilon_{it'}) + \text{Cov}(\epsilon_{it'}, \alpha_i)$$

$$+ x_{it'} \text{Cov}(b_i, \epsilon_{it}) = \sigma_{\alpha}^2 + x_{it} x_{it'} \sigma_b^2 + x_{it'} \sigma_{\alpha b} + x_{it} \sigma_{\alpha b}$$

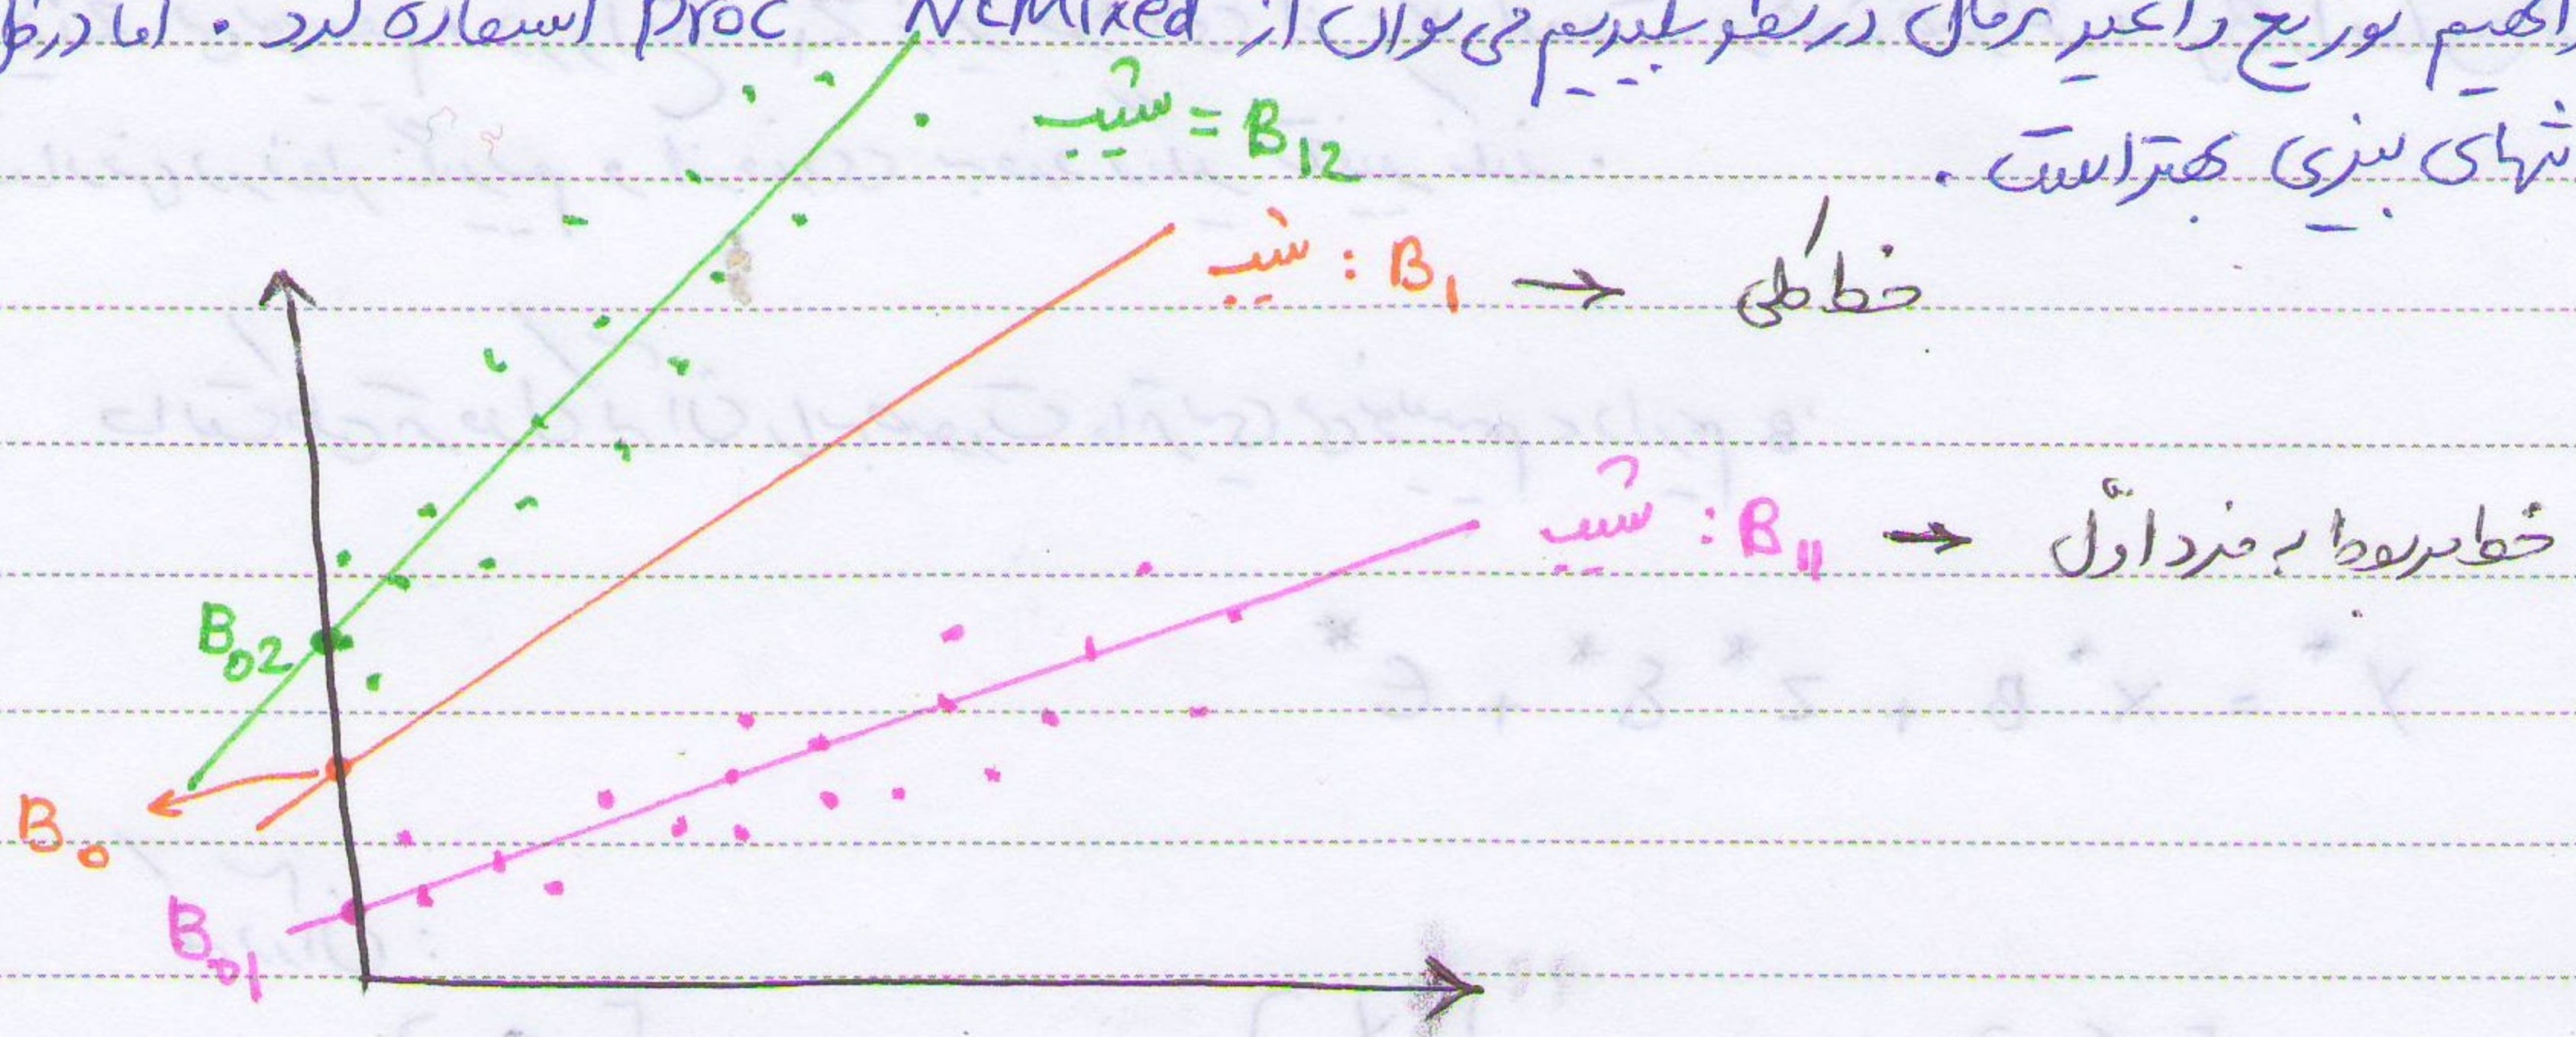
20

$$\text{Var}(\underline{y}_i) = \begin{bmatrix} \sigma_{\alpha}^2 + x_{it}^2 \sigma_b^2 + \sigma_{\epsilon}^2 + 2x_{it} \sigma_{\alpha b} & \sigma_{\alpha}^2 + x_{it} x_{it'} \sigma_b^2 + x_{it'} \sigma_{\alpha b} + x_{it} \sigma_{\alpha b} \dots \\ \dots & \sigma_{\alpha}^2 + x_{it'}^2 \sigma_b^2 + \sigma_{\epsilon}^2 + 2x_{it'} \sigma_{\alpha b} \dots \\ \dots & \dots & \dots \end{bmatrix}$$

25

این ساختار هم چهار پارامتر مجهول دارد که به راحتی قابل برآورد هستند.

در نرم افزار SAS ، با استفاده از Proc mixed می توان انجام داد ، هم چنین اگر
 بخواهیم توزیع را غیر نرمال در نظر بگیریم می توان از Proc nlmixed استفاده کرد . اما در کل
 روش های بیزی بهتر است .



این جانیز برای هر فرد ، خط بررسی می جدا داریم ، فقط در این حالت سبب خطوط نیز با هم فرق دارد

* در بررسی های طولی مقدار n باید زیاد باشد ، چون هدف همان خطی با B_0 و B_1 است ، پس
 باید n زیاد باشد . از لحاظ برعکس داده های سری زمانی ، معمولاً T کم است ، چون اگر T زیاد
 باشد در بررسی ها تغییرات فصلی و ... هم ایجاد می شوند .

* حالت کپی : در حالت کپی ممکن است مدل دارای p متغیر توضیحی باشد ، بنابراین
 داریم :

$$\underline{y_i} = \underline{x_i} \underline{\beta} + z_i \delta_i + \epsilon_i$$

$$\epsilon_i \sim^{iid} N_T(0, \sigma^2 I_T)$$

$$\delta_i \sim N_q(\underline{\alpha}, \underline{\Phi})$$

$$\underline{x_i} = \begin{bmatrix} 1 & x_{i11} & \dots & x_{i1p} \\ 1 & x_{i21} & & x_{i2p} \\ \vdots & \vdots & & \vdots \\ 1 & x_{iT1} & & x_{iTp} \end{bmatrix}$$

بردار x_{i1}

بردار x_{ip}

که شامل T مشاهده فرد است
 که مربوط به متغیر x_1 است .

نکته: دقت کنید که چون ممکن است همه متغیرهای توضیحی را دارای ضریب تصادفی در نظر بگیریم، $z_i \delta_i$ می نویسیم. در واقع z_i زیر مجموعه ای از x_i است و همه ضرایب $z_i B$ را ممکن است تصادفی در نظر بگیریم و از فردی به فرد دیگر تغییر کنند.

حالتی که مدل که آن را به صورت ماتریسی می نویسیم، داریم:

$$y^* = x^* B + z^* \delta^* + \epsilon^*$$

که در آن:

$$\delta^* = \begin{bmatrix} \delta_1 \\ \delta_2 \\ \vdots \\ \delta_n \end{bmatrix}, \quad y^* = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix}, \quad \epsilon^* = \begin{bmatrix} \epsilon_1 \\ \epsilon_2 \\ \vdots \\ \epsilon_n \end{bmatrix}$$

$$x^* = \begin{bmatrix} x_1 & 0 & \dots & 0 \\ 0 & x_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & x_n \end{bmatrix} \xrightarrow{\text{ماتریس}} z^* = \begin{bmatrix} z_1 & 0 & \dots & 0 \\ 0 & z_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & z_n \end{bmatrix}$$

$$V = \text{Var}(y^*) = \begin{bmatrix} \text{Var}(y_1) & 0 & \dots & 0 \\ 0 & \text{Var}(y_2) & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \text{Var}(y_n) \end{bmatrix}$$

$$y^* \sim N_{n_T}(x^* B, V)$$

* برای اینکه likelihood بنویسیم، باید V معلوم باشد، پس از REML استفاده می کنیم و آن را برآورد می کنیم و معلوم می شود.

$$\hat{\beta}_{GLS} = (x^{*'} V^{-1} x^*)^{-1} x^{*'} V^{-1} y^*$$