

روش ژئودتیک ( Geodetic methodology ) : مجموعه ای از فرایندها و ارزیابی ها از مقادیر عددی است که بصورت مستقیم و غیر مستقیم به توضیح و تفسیر هندسه و میدان ثقل زمین می پردازد در عمل برای انجام یک پروژه ژئودتیک یا نقشه برداری باید به مراحل زیر توجه نمود :

۱- شناخت مجهولات و تعیین وقت مورد نیاز برای مجهولات

۲- کلیه راه حل های ممکن برای رسیدن به مجهولات مورد بررسی قرار گیرد ، در حقیقت یک مدل ریاضی برای رسیدن به مجهولات تعیین می شود

۳- انتخاب بهترین راه حل ملن از بین راه حل های موجود

معیارهای بهینگی : الف) وقت ب) زمان ج) هزینه

باتوجه به معیارها در این مرحله یک طرح مشاهداتی ریفه می شود که مشخص می کند به مشاهداتی ، توسط چه دستگاهی و چگونه انجام می پذیرد . (preanalysis)

۴- جمع آوری اطلاعات و مشاهدات مورد نیاز

۵- پردازش رری مشاهدات ( پردازش قبل از سرسنگی ) ، در این مرحله مشاهدات تکراری راست می کنند باید توجه داشت که مشاهدات مورد نیاز برای تست سازگاری باید از یک جاده باشند ( باید توجه داشته باشید که بر مشاهدات مختلف که از یک فینس نیستند یعنی توان تست سازگاری انجام شود )

۶- تشکیل مدل ریاضی و تعیین مجهولات و وقت آن ها ؛ مدل ریاضی : رابطه ایست بین مجهولات و مشاهدات . کیفیت های مختلف یک مدل :

الف) مشاهدات : طول ، زاویه ، ارتفاع ، اختلاف میل ، استدار ، مختصات

ب) مجهولات : طول ، زاویه ، ... بهر دو مختصات و ارتفاع مجهولند

ج) ثابت ها : C ← این مقادیر بوسیله constrain هستند مانند ثابت نیوتن یا مجموع زوایای مثلث معلوم فرمول بندی مدل های ریاضی :

فرمول بندی مدل های ریاضی رابطه ایست میان پارامترهای مجهول و پارامترهای مشاهده شده ، که نقش اساسی و کلیدی در انجام عملیات ژئودتیک بازی می کند ؛ عبارت دیگر مدل ریاضی معضراتی طراحی و پردازش اطلاعات و مشاهدات می باشد .


مدل های ریاضی بطور ساده یک رابطه ریاضی میان یک سری مقادیر دیده شده است که بر پایه قوانین فیزیکی معلوم و قطعی بنا شده اند . بطور سببیک می توان معادله یک مدل ریاضی را بصورت زیر نوشت  $f(q) = 0$  در این رابطه  $q$  یک تابع منحصر بفرد بوده و  $q$  شامل  $n$  مقدار بوده با یک بردار نمایش داده می شود . باتوجه به اینکه یک مدل ریاضی بر پایه فیزیکی قوانین طبیعی یا هندسه مسئله بنا شده است می توان مقادیر  $q$  را کاملاً معلوم در نظر گرفت .

مدل ریاضی ① را باتوجه به پارامترهای ثابت C ، پارامترهای مجهول  $x$  و پارامترهای مشاهده شده  $l$  می توان بصورت زیر نوشت .

$$f(q) = f(c, x, l) = 0 \quad (2)$$

به وضوح مشاهده می شود که بردار  $q$  در رابطه ① به سه جزء در رابطه ② تکلیف شده است . باید توجه داشت که در مدل های مربع می توان از  $c$  صرف نظر نمود و آن را حذف کرد  
توجه : در رابطه ②  $x$  ،  $l$  ،  $solouction$  مدل فیزیکی می شود .

هریک از اجزای رابطه (۷) در فضای مربوط به خود تعریف می‌شوند که رابطه آن‌ها نسبت به هم بصورت زیر می‌باشد



انواع مدل‌ها:

مدل‌های ریاضی می‌توانند مستقیم (direct) و غیرمستقیم (indirect) و implicit variety باشند و هر کدام از آن‌ها می‌توانند خطی یا غیرخطی باشند.

الف) مدل مربع در  $x$ ، این مدل بصورت زیر نوشته می‌شود:  $x = g(l)$ ، از آنجایی که  $g$  یک تابع مربع از فضای مامدات به فضای مجهولات است، لذا هر دو طرف رابطه (۷) منطبق به فضای مجهولات می‌باشند و در اصطلاح گفته می‌شود مدل در فضای مجهولات فرمول‌بندی شده است.

\* مدل خطی مربع در  $x$  (۴)  $x = G l + w$ ، در این رابطه  $G$  ماتریس ترانسفورماسیون از فضای مامدات به فضای مجهولات می‌باشد، اصطلاحاً ماتریس  $G$  را design matrix (ماتریس طراحی) گویند. بردار  $w$  یک بردار ثابت است؛ ماتریس  $G$  و بردار  $w$  شرایط فیزیکی و هندسی را تعیین می‌کنند  $\dim G (u \times n)$  و  $\dim w = u = m$

اگر معادله در فضای مجهولات بصورتی نوشته شود که از وقوع پیغامد مطمئن باشیم، رابطه در شرایط معاینه مجهول نوشته می‌شود و مدل مربع بصورت زیر (certain circumstance)

نوشته خواهد شد (۵)  $g(l) = 0$ ، به این مدل، مدل شرط گوئیم که هندسه و شرایط فیزیکی مدل را در بین مامدات بازسازی کند [معادله شرط رابطه ای بین مامدات است که از یک قانون هندسی یا فیزیکی برگرفته شده است]، رابطه خطی مدل شرط (۶)  $G l + w = 0$



مدل شرط ۸  $\alpha + \beta + \gamma = 180$



$$S = 1/2 l_1 l_2 \sin \alpha$$

مدل مربع در فضای مجهولات

ب) مدل مربع در  $l$ ، غالباً بیان مامدات بر حسب مجهولات آسان تر از معکوس آن می‌باشد، لذا

معادلات مربع در  $l$  (مامدات) بصورت زیر بیان می‌شود (۷)  $l = h(x)$ ، در این رابطه  $h$  تابعی است که می‌توان ترانسفورماسیون از فضای  $x$  به فضای  $l$  از آن یادی کرد، این مدل در فضای مامدات فرمول‌بندی شده است \* رابطه خطی مدل مربع در  $l$  بصورت  $l = H x + w$

بیان می‌شود، در این رابطه ماتریس ترانسفورماسیون از فضای  $x$  به  $l$  می‌باشد که  $\dim$  آن  $\dim w = n = m$  و  $\dim H = (n \times u)$

$$L = \sqrt{(x_1 - x_0)^2 + (y_1 - y_0)^2} : \text{مدل مربع در } l$$



ج) مدل غیرمربع، در بعضی از مثال‌ها و کارها مساهلات را نمی‌توان از هم تفکیک نکرد، لذا این مدل‌ها بصورت زیر نوشته می‌شوند ⑨  $f(x, l) = 0$ ، مدل غیرمربع در فضای مدل فرمول بندی می‌شود  
 لذا  $\dim f = m$  \* فرمول فعلی مدل غیرمربع بصورت زیر خواهد بود ⑩  $Ax + Bl + w = 0$   
 در این رابطه ماتریس  $A$ ، ماتریس طراحی بوده  $\dim A = (m \times n)$ ، ماتریس  $B$  ماتریس طراحی ثانویه  $\dim B = (m \times n)$   
 $\dim w = m$  خواهد بود  
 $f(l_1, l_2, x_1, x_2) = l_1^2 \sin x + (l_2 x_2)^{1/2} = 0$   
 (د) مدل ترکیبی،  
 constrain (قید)  
 $f(x, l) = 0$  مدل مبتدیان  
 $h(x) = 0$  مدل ثانویه  
 همواره در کنار مدل اولیه می‌آید.

۷- پردازش‌های بعد از سرسختی  
 در این مرحله محولات تست می‌شوند که آیا نتایج قابل قبولند یا خیر  
 ۸- ارائه نتایج بصورت مناسب (گرافیکی، عددی و ...)  
 در صورت غیرقابل قبول بودن نتایج، عامل آن پیدا شده و پس از رفع، سرسختی تکرار می‌شود.

مروری بر مفاهیم  
 تعریف مرتبه ماتریس (rank)  $r$  فرض کنید  $A$  ماتریس  $m \times n$  باشد، مرتبه ماتریس  $A$  بزرگترین زیرماتریس مربعی از  $A$  است که درستی آن مخالف صفر باشد. (ماکزیم تعداد سطرها و یا ستونهای مستقل فعلی  $A$  مرتبه ماتریس  $A$  نامیده می‌شود.)  
 فضایی که توسط سطرها یا ستونهای مستقل فعلی  $A$  ماتریس تشکیل شده (ایا ر) می‌شود، فضای سطری  $R(A)$  و فضایی که توسط ستونهای مستقل فعلی  $A$  ماتریس تشکیل شده، فضای  $C(A)$  نامیده می‌شود.

$$\dim(R(A)) = \dim(C(A))$$

$$\text{if } A_{m \times n} \Rightarrow r(A) \leq \min\{m, n\}$$

$$r(A) = r(A^T) = r(AA^T) = r(A^T A)$$

ماتریس  $A$  یک شاست فعلی (ایا ر فطی) است  
 $A_{m \times n} : R^m \rightarrow R^n$   
 $\begin{cases} r(A) = n \rightarrow A \text{ یک به یک است} \\ r(A) = m \rightarrow A \text{ پوشا است} \\ r(A) = m = n \rightarrow A \text{ یک به یک و پوشا است} \end{cases}$

اگر ماتریس  $A$ ، Full rank (بمرتبه کامل) باشد یعنی مرتبه کامل ستونی  $n$  و مرتبه کامل سطری  $m$   $r(A) = m$  در این حالت ماتریس  $A$  را معکوس پذیر، یا وارون پذیر یا غیرسنگولار می‌گویند.

مشتقات ماتریس

۱- مشتق بردار نسبت به اسکالر

$$x_{u \times 1} = \begin{bmatrix} x_1(u) \\ x_2(u) \\ \vdots \\ x_u(u) \end{bmatrix}_{u \times 1} \rightarrow \frac{\partial x}{\partial u} = \begin{bmatrix} \frac{\partial x_1}{\partial u} \\ \vdots \\ \frac{\partial x_u}{\partial u} \end{bmatrix}$$

۲- مشتق تابع اسکالر نسبت به بردار

$$y = f(x) = f(x_1, x_2, \dots, x_n) \quad , \quad x = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix}$$

$$\frac{\partial y}{\partial x} = \left[ \frac{\partial y}{\partial x_1}, \frac{\partial y}{\partial x_2}, \dots, \frac{\partial y}{\partial x_n} \right]$$

۳- مشتق بردار نسبت به بردار

$$y = \begin{bmatrix} y_1(x) \\ y_2(x) \\ \vdots \\ y_m(x) \end{bmatrix} \quad , \quad x = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix} \rightarrow \frac{\partial y}{\partial x} = \begin{bmatrix} \frac{\partial y_1}{\partial x_1} & \dots & \frac{\partial y_1}{\partial x_n} \\ \vdots & & \vdots \\ \frac{\partial y_m}{\partial x_1} & \dots & \frac{\partial y_m}{\partial x_n} \end{bmatrix} = J_y \quad \text{جکوبین}$$

$m \times n$

۴- مشتق ماتریس نسبت به اسکالر

$$A_{m \times n} = \begin{bmatrix} a_{11}(v) & \dots & a_{1n}(v) \\ \vdots & & \vdots \\ a_{m1}(v) & \dots & a_{mn}(v) \end{bmatrix} \rightarrow \frac{\partial A}{\partial v} = \begin{bmatrix} \frac{\partial a_{11}(v)}{\partial v} & \dots & \frac{\partial a_{1n}(v)}{\partial v} \\ \vdots & & \vdots \\ \frac{\partial a_{m1}(v)}{\partial v} & \dots & \frac{\partial a_{mn}(v)}{\partial v} \end{bmatrix}$$

۵- مشتق اسکالر نسبت به ماتریس

$$y = f(A) \quad , \quad A = \begin{bmatrix} a_{11} & \dots & a_{1n} \\ \vdots & & \vdots \\ a_{m1} & \dots & a_{mn} \end{bmatrix} \quad , \quad \frac{\partial y}{\partial A} = \begin{bmatrix} \frac{\partial y}{\partial a_{11}} & \dots & \frac{\partial y}{\partial a_{1n}} \\ \vdots & & \vdots \\ \frac{\partial y}{\partial a_{m1}} & \dots & \frac{\partial y}{\partial a_{mn}} \end{bmatrix}$$

۶- مشتق حاصل ضرب ماتریس نسبت به اسکالر

$$A = A(u) \quad B = B(u) \quad C = A \times B \rightarrow \frac{\partial C}{\partial u} = \frac{\partial A}{\partial u} \times B + A \times \frac{\partial B}{\partial u}$$

$$y = x^T A x \quad \begin{matrix} 1 \times n & n \times n & n \times 1 \end{matrix}$$

۷- مشتق ترم مربع

$$\frac{\partial y}{\partial x} = x^T A + x^T A^T \quad \text{if } A = A^T \Rightarrow \frac{\partial y}{\partial x} = 2x^T A$$

Trace

$$Ax = \lambda x \Rightarrow Ax - \lambda x = 0 \Rightarrow (A - \lambda I)x = 0 \Rightarrow \lambda_i \text{ مقادیر ویژه}$$

$$\textcircled{1} \text{ Trace } A_{n \times n} = \sum_{i=1}^n \lambda_i \quad \left[ \det A_{n \times n} = \prod_{i=1}^n \lambda_i \right]$$

$$\textcircled{2} \text{ Tr}(A+B) = \text{Tr}(A) + \text{Tr}(B)$$

$$\textcircled{3} \text{ Tr}(kA) = k \text{Tr}(A)$$

$$\textcircled{4} \text{ Tr}(AB) = \text{Tr}(BA)$$

$$\textcircled{5} \text{ Tr}(R^T A R) = \text{Tr}(R A R^T) = \text{Tr}(A)$$

$$\textcircled{6} \text{ Tr}(x^T A x) = x^T A x$$



مستات Trace :

$$۱) \frac{\partial \text{Tr}(A)}{\partial A} = \frac{\partial \text{Tr}(A^T)}{\partial A} = I$$

$$۲) \frac{\partial \text{Tr}(A^T B A)}{\partial A} = (B + B^T) A$$

$$۳) \frac{\partial \text{Tr}(A B)}{\partial A} = \frac{\partial \text{Tr}(B A)}{\partial A} = B^T$$

$$۴) \frac{\partial \text{Tr}(A B A^T)}{\partial A} = A(B + B^T)$$

$$۵) \frac{\partial \text{Tr}(A B A^T C)}{\partial A} = C A B + C^T A B^T$$

خط کردن با استاندارد از سبب تکرار:  $y = f(x) = f(x_1, x_2, \dots, x_n)$

اگر بخواهیم تابع فوق را حول نقطه  $x = x_0$  خطی بنویسیم، داریم:

$$y = y_0 + \left. \frac{\partial y}{\partial x_1} \right|_{x=x_0} (x_1 - x_{01}) + \dots + \left. \frac{\partial y}{\partial x_n} \right|_{x=x_0} (x_n - x_{0n}) \quad \text{و} \quad y_0 = f(x_0)$$

$$y_{m \times 1} = \begin{bmatrix} y_1(x) \\ \vdots \\ y_m(x) \end{bmatrix}, \quad x = \begin{bmatrix} x_1 \\ \vdots \\ x_n \end{bmatrix} \rightarrow y_{m \times 1} = y_{0, m \times 1} + \left. \frac{\partial y}{\partial x} \right|_{x=x_0} (x - x_0)$$

بهینه سازی:

۱- بهینه سازی نامعید: هدف تعیین  $\max$  و یا  $\min$  یک تابع اسکالر  $n$  متغیره است

۲- الف) مسائل بهینه سازی معید با مقیدهای مساوی

ب) مسائل بهینه سازی معید با مقیدهای نامساوی

$$۱) y = f(x) = f(x_1, x_2, \dots, x_n) \begin{cases} \rightarrow \max \\ \rightarrow \min \end{cases}$$

$$۲) \begin{cases} y = f(x) = f(x_1, x_2, \dots, x_n) \\ g(x) = 0 \end{cases} \begin{cases} \rightarrow \max \\ \rightarrow \min \end{cases} \quad \text{الف)}$$

$$\begin{cases} y = f(x) = f(x_1, x_2, \dots, x_n) \\ g(x) \geq 0 \text{ یا } \leq 0 \end{cases} \begin{cases} \rightarrow \max \\ \rightarrow \min \end{cases} \quad \text{ب)}$$

بهینه سازی نامعید:

هدف تعیین اکسترمم تابع  $f(x)$  می باشد، شرط لازم برای اینکه نقطه  $x = x^*$  یک نقطه اکسترمم تابع  $y$  باشد اینست که:

$$\left. \frac{\partial y}{\partial x_1} \right|_{x=x^*} = \left. \frac{\partial y}{\partial x_2} \right|_{x=x^*} = \dots = \left. \frac{\partial y}{\partial x_n} \right|_{x=x^*} = 0$$

شرط کافی برای اینکه نقطه  $x = x^*$  یک نقطه  $\max$  باشد اینست که ماتریس هسین تابع معین منفی باشد.  
شرط کافی برای اینکه نقطه  $x = x^*$  یک نقطه  $\min$  باشد اینست که ماتریس هسین تابع معین مثبت باشد.

$$H_f \text{ هسین} = \begin{bmatrix} \frac{\partial^2 f}{\partial x_1^2} & \frac{\partial^2 f}{\partial x_1 \partial x_2} & \dots & \frac{\partial^2 f}{\partial x_1 \partial x_n} \\ \frac{\partial^2 f}{\partial x_2 \partial x_1} & \frac{\partial^2 f}{\partial x_2^2} & \dots & \frac{\partial^2 f}{\partial x_2 \partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 f}{\partial x_n \partial x_1} & \frac{\partial^2 f}{\partial x_n \partial x_2} & \dots & \frac{\partial^2 f}{\partial x_n^2} \end{bmatrix}_{x=x^*}$$

اگر ماتریس  $H$  نیمه مثبت یا نیمه منف باشد راجع به  $x^* = x$  چیزی نمی‌توان گفت، در غیر این حالت ما  $x^* = x$  نقطه زین است.

$$A_{n \times n} = \begin{bmatrix} a_{11} & \dots & a_{1n} \\ \vdots & & \vdots \\ a_{n1} & \dots & a_{nn} \end{bmatrix} \quad A_1 = |a_{11}| \quad A_2 = \begin{vmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{vmatrix} \quad A_K = \begin{vmatrix} a_{11} & \dots & a_{1k} \\ \vdots & & \vdots \\ a_{k1} & \dots & a_{kk} \end{vmatrix}$$

اگر تمامی  $A_i$  ها مثبت باشند در این صورت ماتریس  $A$  معین مثبت است و برعکس (اگر یکی از  $A_i$  ها منفی باشند

ماتریس  $A$  نیمه منفی است)

اگر علامت  $A_i$  ها منفی باشند در این صورت ماتریس  $A$  معین منفی است و برعکس

$$\begin{cases} y = f(x) \begin{cases} \rightarrow \min \\ \rightarrow \max \end{cases} \\ g(x) = 0 \end{cases}$$

بهینه‌سازی مبتنی بر مقادیر مساوی :

روش‌های مختلفی برای حل موجود است یکی از آن‌ها روش لاگرانژ است، اگر  $f$  تابع  $f$ ، با شرط  $g(x) = 0$

می‌توان از اگر  $f$  تابع لاگرانژ استفاده نمود

$$\varphi = f(x) + \lambda^T g(x) \rightarrow \text{اگر } \lambda = \begin{bmatrix} \lambda_1 \\ \vdots \\ \lambda_m \end{bmatrix}$$

در مسئله بهینه‌سازی با قید مساوی، می‌توان از روش لاگرانژ استفاده نمود و آن را به مسئله بهینه‌سازی

نامیده با تابع لاگرانژ با  $(m+n)$  متغیر تبدیل نمود.

$$\varphi = \varphi(x_1, \dots, x_n, \lambda_1, \dots, \lambda_m) \rightarrow \max \text{ or } \min$$

شرط لازم برای تعیین اگر  $f$  تابع  $f$  ضروری است :

$$\left[ \frac{\partial \varphi}{\partial x_1}, \dots, \frac{\partial \varphi}{\partial x_n}, \frac{\partial \varphi}{\partial \lambda_1}, \dots, \frac{\partial \varphi}{\partial \lambda_m} \right] \xrightarrow{\text{همگی}} = 0$$

$n+m$  معادله،  $n+m$  مجهول

(مثال)

$$\begin{cases} x+y=r \\ xy \rightarrow \max \text{ or } \min \end{cases}$$

$$\varphi(x, y, \lambda) = xy + \lambda(x+y-r) \quad \text{تابع لاگرانژ}$$

$$\frac{\partial \varphi}{\partial x} = 0 \Rightarrow y + \lambda = 0$$

$$\frac{\partial \varphi}{\partial y} = 0 \Rightarrow x + \lambda = 0$$

$$\left. \begin{matrix} y + \lambda = 0 \\ x + \lambda = 0 \end{matrix} \right\} x = y$$

$$\rightarrow H = \begin{bmatrix} 0 & 1 & 1 \\ 1 & 0 & 1 \\ 1 & 1 & 0 \end{bmatrix} \Rightarrow \begin{cases} H_1 = 0 \\ H_2 = -1 \\ H_3 = 0 \end{cases}$$

$$\frac{\partial \varphi}{\partial \lambda} = 0 \Rightarrow x+y-r=0 \Rightarrow \begin{cases} x = \frac{r}{2} \\ y = \frac{r}{2} \end{cases}$$



وارون ماتریس‌های پارامترهای سری:

$$A_{n \times n} = \begin{bmatrix} A^{1 \times 1}_{m \times m} & A^{1 \times 2}_{m \times (n-m)} \\ A^{2 \times 1}_{(n-m) \times m} & A^{2 \times 2}_{(n-m) \times (n-m)} \end{bmatrix}$$

$$B = A^{-1} = \begin{bmatrix} B_{11} & B_{12} \\ B_{21} & B_{22} \end{bmatrix}$$

الف) if  $A, A_{11}$  nonsingular

$$B_{11} = A_{11}^{-1} - A_{11}^{-1} A_{12} B_{21}$$

$$B_{21} = -B_{22} A_{21} A_{11}^{-1}$$

$$B_{12} = -A_{11}^{-1} A_{12} B_{22}$$

$$B_{22} = A_{22} - A_{21} A_{11}^{-1} A_{12}$$

ب) if  $A, A_{22}$  nonsingular

$$B_{11} = (A_{11} - A_{12} A_{22}^{-1} A_{21})^{-1}$$

$$B_{21} = -A_{22}^{-1} A_{21} B_{11}$$

$$B_{12} = -B_{11} A_{12} A_{22}^{-1}$$

$$B_{22} = A_{22}^{-1} - A_{22}^{-1} A_{21} A_{11}^{-1} A_{12}$$

$$(C^{-1} + A^T B^{-1} A)^{-1} = C - C A^T (B + A C A^T)^{-1} A C$$

مشاهدات و ویژگی‌های آن‌ها:

برای مشخص کردن مفهوم یک مشاهده می‌بایست اندازه‌گیری را در زمان و در فضا معرفی نمود، عنوان مثال حاصل در نقطه بر روی زمین را می‌توان به صورت اندازه‌گیری ماسدوم در طول زمان انجام داده و یک سری زمانی ایجاد نمود، حال می‌توان این اندازه‌گیری را بین نقاط مختلف انجام داده و یک سری مشاهدات در فضا ایجاد نمود.

سری زمانی  $i = 1, \dots, N$  و  $L(z_i)$

به هر مشاهده انجام شده در زمان  $z_i$  یک نمونه (sample point) گفته می‌شود.

هر مشاهده انجام شده  $L(z)$  بطور عمده شامل یک قسمت معین (deterministic) و یک قسمت تصادفی (stochastic) می‌باشد، که قسمت معین را ترند (trend) و قسمت تصادفی را باقی‌مانده (residual) گویند.

$$L(z) = t(z) + r(z) \quad (11)$$

قسمت معین ( $t$ ) خود از دو جزء تشکیل شده، یک مقدار  $\hat{L}(z)$  که میان مقدار مورد انتظار است و  $p(z)$

$$t(z) = \hat{L}(z) + p(z) \quad (12)$$

که جزء سیستماتیک می‌باشد.  $p(z)$  باعث تغییر مشاهدات شده و آن را می‌توان به کمک یک فرمول بر حسب یک سری پارامترهای معلوم بیان نمود، این پارامترها همان ترند سیستماتیک بوده که مشاهدات را تحت تأثیر قرار می‌دهند و تماماً در طول مشاهدات (ترند اندازه‌گیری مشاهدات) رفع نشده اند.

$$p(z) = \phi(z) \lambda \quad (13)$$

در رابطه بالا  $\phi(z)$  یک سطر از ماتریس واندروند است که توابع کاربرد در آن بر حسب توابع

پایه‌نوسه شده اند. (فصل 14.2 concept)

متادیر  $\lambda$  را گاهی پارامترهای نویز  $\lambda$  nuisance parameters گویند، عنوان مثال در شبکه طولیاب می‌تواند یک سری

پارامترهای مدل اعمال کند.

در بعضی از کارها اگر بخواهیم برسیانده به قفیه نامه کنیم می توان یک سری از پارامترهای نویز را به صورت مجزا همراه با مجهولات  $X$  در نظر گرفت و آن ها را محاسبه نمود.

$$r(z) = v(z) + s(z) \quad (14)$$

$s$  و  $v$  دو مقدار تصادفی هستند که ویران آن ها به ضربه فیلتر یکین پدیده بستگی دارد که به خوبی از آن مطلع نیستیم. با ضربه  $v$  یک مقدار تصادفی (آماري) است که مستقل بوده و مقدار آن به کمک روش های آماری قابل پیگیری می باشد. این مقدار اغلب مربوط به لوازم اندازه گیری بوده و پس محضریه آن نیست. مقدار متوسط این با ضربه محضریه باشد.

با ضربه  $s$  یک متغیر تصادفی وابسته بوده که مربوط رفتار ویژه آن مأمورات در یک تکرار فاهن می باشد (اساس ایجاد آن خارج از سیستم اندازه گیری است و به حقیقت بستگی دارد)، با ضربه  $s$  هم تصادفی است در نتیجه میانگین آن صفر است. (گاهی یک متغیر تصادفی وابسته را (مطورمان) با ضربه تصادفی وابسته است) را signal گویند.

$$l = \hat{l} + p - v - s \quad (15)$$

باتوجه به مطالب گفته شده برار مأمورات به صورت :



نصل اول:

مراحل انجام پروژه است بر داری:

- 1- شناسایی جهت و تعیین دست مورد نیاز برای مجموعه‌ها
- 2- کشف راه‌های ممکن برای رسیدن به مجموعه‌ها مورد بررسی قرار گیرد. در حقیقت یک مدل ریاضی برای رسیدن به مجموعه‌ها تعیین می‌شود.
- 3- انتخاب بهترین راه حل از بین راه‌های ممکن
- 4- جمع‌آوری اطلاعات دست‌ها و مورد نیاز
- 5- پردازش روی دست‌ها (پردازش‌های قبلی از سه شگنی). در این مرحله دست‌های نامشروع است در درگیری باشند. سازگاری دست‌ها مختلف با هم سنجیده نمی‌شوند. در این مرحله سازگاری دست‌های نامشروع است که در آن یک جابجایی باشند.
- 6- شکل مدل ریاضی و تعیین مجموعه‌ها و دست‌ها و مجموعه‌ها (رابطه‌ای است بین مجموعه‌ها و دست‌ها)
- کمیته‌های مختلف یک مدل ریاضی  $\rightarrow$  1- دست‌ها: طول، زاویه، ارتفاع، اختلاف نقل، اعداد، محاسبات  $\rightarrow L$
- 2- مجموعه‌ها: طول، زاویه، ...  $\rightarrow$  مجموعه‌ها و ارتفاع مجموعه‌ها  $\rightarrow X$
- 3- ثابت  $\rightarrow C$



انواع مدل‌های ریاضی:

الف) مدل مستقیم: مدل است که نسبت به مجموعه‌ها صریح است که می‌تواند خطی یا غیر خطی باشد

$$x_{ux1} = A_{uxn} L_{nx1} \quad \text{یا} \quad x_{ux1} = f_{ux1}(L_{nx1}) \quad (\text{غیر خطی})$$

فضای مجموعه‌ها

فضای دست‌ها



$$S = \frac{1}{2} L_1 L_2 \sin \alpha$$

مدل مستقیم در فضای مجموعه‌ها نوشته می‌شود


بدون غیر سیستم: مدلی است که نسبت به شش هداات صریح است که می تواند خطی یا غیر خطی باشد (مدل معکوس هم میگویند)

$$L_{n \times 1} = A_{n \times u} x_{u \times 1} \quad \text{خطی} \quad \underline{L}_{n \times 1} = f_{n \times 1}(x_{u \times 1}) \quad \text{غیر خطی}$$

فضای مجهولات

فضای مشاهدات

مدل غیر سیستم در فضای مشاهدات فرستاده می شود



$A$



$$L = \sqrt{(x_1 - x_0)^2 + (y_1 - y_0)^2} \quad \text{طول یا خط}$$

2) مدل ترکیبی: که نسبت به مجهولات صریح است نسبت به شش هداات که می تواند خطی یا غیر خطی باشد.

$$\begin{cases} \text{خطی} \rightarrow A_{r \times u} x_{u \times 1} + B_{r \times n} L_{n \times 1} + C_{r \times 1} = 0 \\ \text{غیر خطی} \rightarrow f_{r \times 1}(x_{u \times 1}, L_{n \times 1}) = 0 \end{cases}$$

$u$ : تعداد مجهولات

$n$ : تعداد مشاهدات

$r$ : تعداد معادلات

مدلهای ترکیبی: توضیح این مدل بعداً داده خواهد شد

7) پردازش های بعد از سختی

در این مرحله مجهولات سخت می شوند که آرایشی قابل قبولند یا خیر

8- آرایش نتایج به صورت های مناسب (گرافیکی، عددی و ...)

در صورت غیر قابل بودن نتایج عامل آن پیدا شده و پس از رفع سختی تکرار شود

مردی بر حسب خطی!

تعریف رتبه ماتریس: (RANK):

فرض کنید  $A$  ماتریسی  $m \times n$  باشد. رتبه ماتریس  $A$  بزرگترین زیرماتریس مربعی از  $A$  است که در میان آن مخالف صفر باشد

(ماتریس عدد اسطرک و یا ستونهای مستقل خطی ماتریس  $A$  رتبه ماتریس  $A$  نامیده می شود)

\* ماتریس عدد اسطرک های مستقل خطی یک ماتریس همیشه با ماتریس عدد ستونهای مستقل خطی ماتریس برابر می باشد

$$\text{رتبه ماتریس } A = R(A) = \text{RANK}(A)$$



\* فضای که توسط سطرهای مستقل خطی یک ماتریس تشکیل شده فضای که توسط ستونهای مستقل خطی یک ماتریس تشکیل شده  
 شود، فضای  $C(A)$  نامیده می شود.

$$\dim(R(A)) = \dim(C(A))$$

اگر  $A \in \mathbb{R}^{m \times n}$   $\rightarrow$  1)  $r(A) \leq \min\{m, n\}$

باشد 2)  $r(A \times B) = r(AB) \leq \min\{r(A), r(B)\}$

3)  $r(A+B) \leq r(A) + r(B)$

4)  $r(A) = r(A^T) = r(AA^T) = r(A^T A)$

$A^T = A \rightarrow$  متقارن است  $A$

$A = \bar{A}^T = A^* \rightarrow$  هرمیتی است  $A$

نکته: ماتریس  $A$  یک نگاشت دیک ایراتور خطی است.

$$A_{m \times n} : \mathbb{R}^n \rightarrow \mathbb{R}^m$$

$$\phi^n \rightarrow \phi^m$$

ایراتور خطی حالت خاصی از نگاشت می باشد

$$\begin{cases} A(x+y) = A(x) + A(y) \\ A(\alpha x) = \alpha A(x) \end{cases}$$

$A_{m \times n} :$   $\begin{cases} r(A) = n \rightarrow A \text{ یک رتبه یک است} \\ r(A) = m \rightarrow A \text{ پهن است} \\ r(A) = m = n \rightarrow A \text{ یک رتبه و پهن است} \end{cases}$

$A$  ماتریس full rank است  $\rightarrow$  (رتبه کامل ستونی)  $= n$  یا (رتبه کامل سطری)  $= m$   $r(A) =$

$A$  ماتریس nonsingular است  $\rightarrow r(A) = m = n$

دارون کمی معروف  $A_{m \times n}$

1)  $r(A) = m = n \rightarrow AA^{-1} = A^{-1}A = I \rightarrow A^{-1}$  دارون حقیقی است که معکوس فردینمی باشد

$$2) r(A) = n \rightarrow \bar{A}_L^{-1} A = I \rightarrow A \text{ دارای وارون چپ است که مخفف فرزند می باشد}$$

یکی از این وارونها که مخفف به جواب بکترین درجات می شود از رابطه زیر محاسبه میگردد

$$r(A) = n < m \rightarrow \bar{A}_L^{-1} = (A^T A)^{-1} A^T$$

$$3) r(A) = m < n$$

A وارون راست دارد که مخفف فرزند می باشد

$$A \bar{A}_R^{-1} = I$$

یکی از این وارونها که مخفف فرزند می باشد و مخفف به جواب می نم ی شود از رابطه زیر بدست می آید:

$$\bar{A}_R^{-1} = A^T (A A^T)^{-1}$$

$$4) r(A) < \min \{m, n\} \rightarrow$$

در این صورت ماتریس A دارای وارونی خواهد بود به نام شبه وارون که:

$$1) A A^+ A = A$$

$$3) A^+ A A^+ = A^+$$

$$2) (A^+ A)^T = A^+ A$$

$$4) (A A^+)^T = A A^+$$

شبه وارون هر ماتریسی مخفف فرزند است. وارون حقیقی و وارون چپ و راست خاص، خود حالتی خاص از شبه وارون هستند. عموماً ماتریس معین مثبت:

ماتریس هرمیتی A معین مثبت است اگر و تنها اگر  
↓  
(p.d.)

$$\forall x \neq 0 \in \mathbb{C}^n ; x^H A x > 0$$

$$\text{if } A = \bar{A}^T = A^H \rightarrow A \text{ is Hermitian}$$

عموماً ماتریس معین منفی (n.d.):

$$x^H A x < 0 \rightarrow A \text{ معین منفی}$$

ماتریس نیمه معین مثبت:

$$\forall x \in \mathbb{C}^n \rightarrow x^H A x \geq 0 \rightarrow A \text{ نیمه معین مثبت}$$

ماتریس نیمه معین منفی:

$$\forall x \in \mathbb{C}^n \rightarrow x^H A x \leq 0 \rightarrow A \text{ نیمه معین منفی}$$

قضیه:

اگر برای هر  $x \in \mathbb{C}^n$   $x^H A x \in \mathbb{R}$  در این صورت  $A$  هرمیتی است و بالعکس



سنگین  
قضیه:

ماتریس مربعی  $A$  معین مثبت است اگر و تنها اگر تمام حادیر وثره اش مثبت باشند.  
ماتریس مربعی  $A$  معین منفی است اگر و تنها اگر تمام حادیر وثره اش منفی باشند.  
ماتریس مربعی  $A$  نیمه معین مثبت است اگر و تنها اگر تمام حادیر وثره اش نامنفی باشند.  
ماتریس مربعی  $A$  نیمه معین منفی است اگر و تنها اگر تمام حادیر وثره اش نامثبت باشند.

قضیه:

اگر ماتریسی  $p.d$  یا  $n.d$  باشد حتماً دارای وارون حقیقی است ولی عکس این قضیه صادق نمی باشد.

نرمش:

$$M_{m \times m} : p.d \quad , \quad N_{n \times n} : p.d \quad , \quad A_{n \times m}$$

قضیه:

$$1) r(A) = r(A^T) = r(AMA^T) = r(A^TNA)$$

$$2) A_{m \times n}^T N_{n \times n} A_{n \times m} \rightarrow \text{is } p.d \text{ if } r(A) = m$$

$$\rightarrow \text{is } p.s.d \text{ if } r(A) \neq m \quad (r(A) < m)$$

$$3) A_{n \times m} M_{m \times m} A_{m \times n}^T \rightarrow \text{is } p.d \text{ if } r(A) = n$$

$$\rightarrow \text{is } p.s.d \text{ if } r(A) \neq n \quad (< n)$$

$$A_{m \times n} \text{ و } B_{p \times n} \rightarrow AB^T = 0 \rightarrow r \begin{bmatrix} A \\ B \end{bmatrix}_{(m+p) \times n} = r(A) + r(B)$$

$$(A_{m \times n} x_{n \times 1} = 0 \rightarrow x = 0) \leftrightarrow r(A) = n$$

مشتقات ماتریسی:

$$x_{u \times 1} = \begin{bmatrix} x_1(u) \\ x_2(u) \\ \vdots \\ x_u(u) \end{bmatrix}_{u \times 1} \rightarrow \frac{\partial x}{\partial u} = \begin{bmatrix} \frac{\partial x_1}{\partial u} \\ \vdots \\ \frac{\partial x_u}{\partial u} \end{bmatrix}_{u \times 1}$$

۱- مشتق بردار نسبت به اسکالر

2) مشتق تابع اسکالر نسبت به بردار

$$y = f(x) = f(x_1, x_2, \dots, x_n) \quad , \quad x = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix}$$

$$\rightarrow \frac{\partial y}{\partial x} = \left[ \frac{\partial y}{\partial x_1} \quad \frac{\partial y}{\partial x_2} \quad \dots \quad \frac{\partial y}{\partial x_n} \right]_{1 \times n}$$

3) مشتق بردار نسبت به بردار

$$y = \begin{bmatrix} y_1(x) \\ y_2(x) \\ \vdots \\ y_m(x) \end{bmatrix} \quad , \quad x = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix} \rightarrow \frac{\partial y}{\partial x} = \begin{bmatrix} \frac{\partial y_1}{\partial x_1} & \dots & \frac{\partial y_1}{\partial x_n} \\ \vdots & & \vdots \\ \frac{\partial y_m}{\partial x_1} & \dots & \frac{\partial y_m}{\partial x_n} \end{bmatrix}_{m \times n} = J_{yx} \quad \text{ژاکوبین}$$

4) مشتق ماتریس نسبت به اسکالر

$$A_{m \times n} = \begin{bmatrix} a_{11}(v) & \dots & a_{1n}(v) \\ \vdots & & \vdots \\ a_{m1}(v) & \dots & a_{mn}(v) \end{bmatrix} \rightarrow \frac{\partial A}{\partial v} = \begin{bmatrix} \frac{\partial a_{11}(v)}{\partial v} & \dots & \frac{\partial a_{1n}(v)}{\partial v} \\ \vdots & & \vdots \\ \frac{\partial a_{m1}(v)}{\partial v} & \dots & \frac{\partial a_{mn}(v)}{\partial v} \end{bmatrix}$$

5) مشتق اسکالر نسبت به ماتریس

$$y = f(A) \quad , \quad A = \begin{bmatrix} a_{11} & \dots & a_{1n} \\ \vdots & & \vdots \\ a_{m1} & \dots & a_{mn} \end{bmatrix}$$

مثال:

$$\frac{\partial y}{\partial A} = \begin{bmatrix} \frac{\partial y}{\partial a_{11}} & \dots & \frac{\partial y}{\partial a_{1n}} \\ \vdots & & \vdots \\ \frac{\partial y}{\partial a_{m1}} & \dots & \frac{\partial y}{\partial a_{mn}} \end{bmatrix}_{m \times n}$$

$$y = \text{tr}(A) \rightarrow \frac{\partial y}{\partial A} = I_{n \times m}$$

6) مشتق حاصل ضرب ماتریس نسبت به اسکالر

$$A = A(v)$$

$$C = A \times B \rightarrow \frac{\partial C}{\partial v} = \frac{\partial A}{\partial v} \times B + A \times \frac{\partial B}{\partial v}$$

$$B = B(v)$$

7) مشتق نرم نرمی

$$y = x_{1 \times n}^H A_{n \times n} x_{n \times 1} \quad \left\{ (x^T A x) \right\}$$

$$\frac{\partial y}{\partial x} = x^H A + x^H A^H \quad \left\{ (x^T A + x^T A^T) \right\}$$

$$\text{if } A = A^H \quad \left\{ (A = A^T) \right\}$$

$$\frac{\partial y}{\partial x} = 2 x^H A \quad \left\{ (2 x^T A) \right\}$$

$$1) y = A_{m \times n} x_{n \times 1} \rightarrow \frac{\partial y}{\partial x} = A$$

$$2) y = x_{1 \times n}^T A_{n \times m} \rightarrow \frac{\partial y}{\partial x} = A^T$$

قوانین Trace :

$$1) \text{Trace}(A_{n \times n}) = \sum_{i=1}^n \lambda_i \quad \left[ \det(A) = \prod_{i=1}^n \lambda_i \right]$$

$$2) \text{Tr}(A+B) = \text{Tr}(A) + \text{Tr}(B)$$

$$3) \text{Tr}(KA) = K \text{Tr}(A) \quad (K = \text{عدد})$$

$$4) \text{Tr}(AB) = \text{Tr}(BA)$$

$$5) \text{Tr}(A^T B) = \text{Tr}(B^T A) = \text{Tr}(AB^T) = \text{Tr}(BA^T)$$

$$6) \text{Tr}(R^{-1}AR) = \text{Tr}(RAR^{-1}) = \text{Tr}(A)$$

$$7) \text{Tr} \left( \underset{1 \times n}{x^T} \underset{n \times n}{A} \underset{n \times 1}{x} \right) = x^T A x$$

مشتقات Trace :

$$1) \frac{\partial \text{tr}(A)}{\partial A} = \frac{\partial \text{Tr}(A^T)}{\partial A} = I$$

$$2) \frac{\partial \text{Tr}(A^T B A)}{\partial A} = (B + B^T) A$$

$$3) \frac{\partial \text{Tr}(AB)}{\partial A} = \frac{\partial \text{Tr}(BA)}{\partial A} = B^T$$

$$4) \frac{\partial \text{Tr}(ABA^T)}{\partial A} = A(B + B^T)$$

$$5) \frac{\partial \text{Tr}(ABA^T C)}{\partial A} = CAB + C^T A B^T$$

خطی کردن با استفاده از بسط سری تیلور :

$$y = f(x) = f(x_1, \dots, x_n)$$

اگر بخواهیم تابع فوق را حول نقطه  $x = x_0$  خطی کنیم داریم :

$$y = y_0 + \left. \frac{\partial y}{\partial x_1} \right|_{x=x_0} (x_1 - x_{01}) + \dots + \left. \frac{\partial y}{\partial x_n} \right|_{x=x_0} (x_n - x_{0n}) \quad \text{و } y_0 = f(x_0)$$

در حالت کلی :

$$y_{m \times 1} = \begin{bmatrix} y_1(x) \\ \vdots \\ y_m(x) \end{bmatrix}, \quad x = \begin{bmatrix} x_1 \\ \vdots \\ x_n \end{bmatrix} \rightarrow y_{m \times 1} = y_{0, m \times 1} + \left. \frac{\partial y}{\partial x} \right|_{x=x_0} (x - x_0)$$

به زائوس



1- مسئله کینه سازی با مقید هدف تعیین  $\max$  یا  $\min$  یک تابع اسکالر  $n$  متغیره است

2- الف) مسئله کینه سازی مقید با شرط های مساوی

ب- مسئله کینه سازی مقید با شرط های نامساوی

✓ 1)  $y = f(x) = f(x_1, \dots, x_n) \rightarrow \begin{cases} \max \\ \min \end{cases}$

سرشکلی

✓ 2- الف)  $\begin{cases} y = f(x) = f(x_1, \dots, x_n) \rightarrow \begin{cases} \max \\ \min \end{cases} \\ g(x) = 0 \end{cases}$

\* 2- ب)  $\begin{cases} y = f(x) \rightarrow \begin{cases} \max \\ \min \end{cases} \\ g(x) \geq 0 \text{ یا } \leq 0 \end{cases}$

کینه سازی با مقید:

هدف تعیین اسکالر تابع  $y = f(x)$  می باشد. شرط لازم برای اینکه نقطه  $x = x^*$  یک نقطه اسکالر تابع  $y$  باشد اینست که:

$$\left. \frac{\partial y}{\partial x_1} \right|_{x=x^*} = \left. \frac{\partial y}{\partial x_2} \right|_{x=x^*} = \dots = \left. \frac{\partial y}{\partial x_n} \right|_{x=x^*} = 0$$

شرط کافی برای اینکه نقطه  $x = x^*$  یک نقطه  $\max$  باشد این است که ماتریس هسین تابع  $f$  معین منفی باشد.  
شرط کافی برای اینکه نقطه  $x = x^*$  یک نقطه  $\min$  باشد این است که ماتریس هسین تابع  $f$  معین مثبت باشد.

$$H_f = \begin{bmatrix} \frac{\partial^2 f}{\partial x_1^2} & \frac{\partial^2 f}{\partial x_1 \partial x_2} & \dots & \frac{\partial^2 f}{\partial x_1 \partial x_n} \\ \frac{\partial^2 f}{\partial x_2 \partial x_1} & \frac{\partial^2 f}{\partial x_2^2} & \dots & \frac{\partial^2 f}{\partial x_2 \partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 f}{\partial x_n \partial x_1} & \frac{\partial^2 f}{\partial x_n \partial x_2} & \dots & \frac{\partial^2 f}{\partial x_n^2} \end{bmatrix}_{x=x^*}$$

\* اگر ماتریس  $H$  نیمه معین مثبت یا نیمه معین منفی باشد راجع به  $x = x^*$  چیزی نمی توان گفت. در غیر این حالت که  $x = x^*$  نقطه سرجی است

$$A_{n \times n} = \begin{bmatrix} a_{11} & \dots & a_{1n} \\ \vdots & & \vdots \\ a_{n1} & \dots & a_{nn} \end{bmatrix} \quad A_1 = |a_{11}| \quad , \quad A_2 = \begin{vmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{vmatrix} \quad , \quad A_k = \begin{vmatrix} a_{11} & \dots & a_{1k} \\ \vdots & & \vdots \\ a_{k1} & \dots & a_{kk} \end{vmatrix}$$

- \* اگر  $A_i$  مثبت باشد در این صورت ماتریس  $A$  معین مثبت و برعکس (معین  $A_i$  منفی باشد  $\rightarrow$  معین مثبت)
- \* اگر علامت  $A_i$  برابر  $(-1)^i$  بود در این صورت ماتریس  $A$  معین منفی است و برعکس

کهنه سازی مبتنی بر معادلاتی می باشد:

$$y = f(x) \begin{cases} \rightarrow \min \\ \rightarrow \max \end{cases}$$

$$g(x) = 0$$

$m \times 1$

روشهای مختلفی برای حل وجود است که یکی از آنها روش لاگرانژ است. برای تعیین اکستریم تابع  $f$  باشد  $g(x) = 0$  می توان از اکستریم تابع لاگرانژ استفاده کرد.

$$\varphi = f(x) + \lambda^T g(x) \rightarrow \text{اکستریم}, \lambda = \begin{bmatrix} \lambda_1 \\ \vdots \\ \lambda_m \end{bmatrix}$$

لذا مسئله کهنه سازی مبتنی بر معادلاتی می باشد که متغیرهای  $(n+m)$  متغیری شود.

$$\varphi = \varphi(x_1, \dots, x_n, \lambda_1, \dots, \lambda_m) \rightarrow \max \text{ or } \min$$

شرط لازم برای تعیین اکستریم تابع  $\varphi$  این است که

$$\left[ \frac{\partial \varphi}{\partial x_1}, \dots, \frac{\partial \varphi}{\partial x_n}, \frac{\partial \varphi}{\partial \lambda_1}, \dots, \frac{\partial \varphi}{\partial \lambda_m} \right] \xrightarrow{\text{مصفی}} = 0$$

$n+m$  معادله و  $n+m$  مجهول

$$x+y=r$$

$$xy \rightarrow \max \text{ or } \min$$

$$\varphi(x, y, \lambda) = xy + \lambda(x+y-r)$$

$$\begin{aligned} \frac{\partial \varphi}{\partial x} = 0 &\rightarrow y + \lambda = 0 \\ \frac{\partial \varphi}{\partial y} = 0 &\rightarrow x + \lambda = 0 \end{aligned} \rightarrow x = y$$

$$\rightarrow H = \begin{bmatrix} 0 & 1 & 1 \\ 1 & 0 & 1 \\ 1 & 1 & 0 \end{bmatrix} \quad \begin{cases} H_1 = 0 \\ H_2 = -1 \\ H_3 = 0 \end{cases}$$

$$\frac{\partial \varphi}{\partial \lambda} = 0 \rightarrow x+y-r=0 \rightarrow \begin{cases} x = \frac{r}{2} \\ y = \frac{r}{2} \end{cases}$$

دارون ماتریس های پارتیشن بندی شده:

$$A_{n \times n} = \begin{bmatrix} A_{1 \times 1} & A_{1 \times 2} \\ A_{2 \times 1} & A_{2 \times 2} \end{bmatrix}$$

$$B = A^{-1} = \begin{bmatrix} B_{11} & B_{12} \\ B_{21} & B_{22} \end{bmatrix}$$

الف) if  $A, A_{11}$  non singular

$$B_{22} = (A_{22} - A_{21} A_{11}^{-1} A_{12})$$

$$B_{21} = -B_{22} A_{21} A_{11}^{-1}$$

$$B_{12} = -A_{11}^{-1} A_{12} B_{22}$$

$$B_{11} = A_{11}^{-1} - A_{11}^{-1} A_{12} B_{21}$$

ب) if  $A, A_{22}$  non singular

$$B_{11} = (A_{11} - A_{12} A_{22}^{-1} A_{21})^{-1}$$

$$B_{12} = -B_{11} A_{12} A_{22}^{-1}$$

$$B_{21} = -A_{22}^{-1} A_{21} B_{11}$$

$$B_{22} = A_{22}^{-1} - A_{22}^{-1} A_{21} A_{12}$$

$$(C^T + A^T B A)^{-1} = C - C A^T (B + A C A^T)^{-1} A C$$

فصل دوم

علت نیاز به سرنگی

در دستگاه های که معمولاً در علوم فیزیک و مهندسی با آنها سروکار داریم، ماتریس  $A$  در معادلات  $L_{n \times 1} = A X_{n \times 1}$  به ازای مرتبه  $n$  یک معادله نوشت افزاینده معادلات ندارند.  $r(A) \neq r(D)$  به عبارت دیگر در معادلات  $L_{n \times 1} = A X_{n \times 1}$  ما چنین اندیشه می توانیم به ازای مرتبه  $n$  یک معادله نوشت افزاینده معادلات نسبت به مجهولات در صورتی امکان پذیر است که تعدادی از معادلات اضافی داشته باشیم. دلیل انجام این معادلات اضافی در مدل های سرنگی به صورت زیر می باشد:

1- امکان کنترل معادلات (از حيث وجود داشته، خطای سیستم و...) تنها زمانی امکان پذیر است که معادلات اضافی داشته باشیم

2- رسیدن به جواب بهتر در صورتی امکان پذیر است که معادلات اضافی داشته باشیم

3- امکان برآورد پارامترهای کیفی مجهولات در معادلات در صورتی امکان پذیر است که معادلات اضافی داشته باشیم

معادلات اضافی به (1) تکرار یک معادله که معادلات از یک جامعه برداشت شده باشند

(2) معادلات کمیت های دیگرانه

معادله انجام تکرار معادله:

معادله وجود داشته، رسیدن به جواب بهتر، است نواقص بودن

معادله کمیت های دیگر:

معادله وجود خطای سیستم، رسیدن به جواب بهتر



نمبر این دستگاه های که با آنها سروکار خواهیم داشت از نوع دستگاه های نامرگانه است و دلیل عدم وجود جواب میباشد.  
 دستگاه معادلات خطی زیر را در نظر بگیرید

$$L_{n \times 1} = A_{n \times u} x_{u \times 1} \quad n > u$$


$$r(A) \neq r(D)$$

نامرگاری دیگر عدم تساوی سمت چپ در است معادله قبل است.

$$L = A x$$

فضای برداری      فضای فیزیکی (خطا دار)

مثال:



طول واقعی  $AB = 100 \text{ m}$

طول درآشده  $AB = 100.02 \text{ m}$

$$100.02 \neq \sqrt{(x_A - x_B)^2 + (y_A - y_B)^2}$$

در دستگاه معادلات 1 نامرگاری دیگری به چشم میخورد که عدم تساوی سمت چپ در است معادله که به علت وجود خطا در فضای فیزیکی (آلوده به خطا) و معادلات در فضای برداری میباشد.

$$L_{n \times 1} \neq A_{n \times u} x_{u \times 1} \quad n > u$$

$$L_{n \times 1} + v_{n \times 1} = A_{n \times u} x_{u \times 1}$$

→  $\begin{matrix} n+u & \text{جهت} \\ n & \text{معادلات} \end{matrix}$

تبدیل عدم تساوی به تساوی و تبدیل دستگاه به جواب به دستگاه ای بنامت جواب

تحويلات طاری (تصحیح معادلات)

$$L = A x - v = \begin{bmatrix} A & -I \\ \hline \end{bmatrix} \begin{bmatrix} x_{u \times 1} \\ v_{n \times 1} \end{bmatrix} = A^*_{n \times (n+u)} x^*_{(n+u) \times 1}$$

$I$  ماتریس ایزوله  $A$  و  $A^*$

$$D = \begin{bmatrix} A^* & | & L_{n \times 1} \end{bmatrix}_{n(n+u+1)}$$

$$\left. \begin{matrix} r(A^*) \leq n & (\text{محدود } A^*) \\ r(A^*) \geq n & (\text{بدلیل وجود } I \text{ در } A^*) \end{matrix} \right\} \rightarrow r(A^*) = n$$

$$r(A^*) = r(D) = n < n+u$$

دستگاه ای بنامت جواب

$$\left. \begin{matrix} r(D) \leq n & (\text{بدلیل محدود } D) \\ r(D) \geq n & (\text{بدلیل وجود } A^* \text{ در } D) \end{matrix} \right\} \rightarrow r(D) = n$$

$$L = A^* x^*$$

دستگاه معادلات  $L = A^* x^*$  دستگاش است بای نهایت جواب، هدف این است که یک جواب از بی نهایت جواب اینی شود، به طوری که حاصل خصوصیات آماري خوبی داشته باشد، برای اینکه یک جواب از بی نهایت جواب اینی شود لازم است تا بی نهایت خصوصیات  $f(x^*)$  به معادلات اضافه شود

$$\begin{cases} L = A^* x^* \\ f(x^*) \rightarrow \min \text{ or } \max \end{cases}$$

بنابراین باید ما که تکنیک سازی سر و کار خواهیم داشت. به نابع هدفی که معمولاً در علوم ژئوماتیک استفاده می گردد  $\min$  کردن تابع نرم است. ثابت می شود اگر از  $\min$  کردن تابع نرم استفاده شود، جواب حاصل خصوصیات آماري خوبی خواهد داشت که در تئوری تقریب فوق القاصم است.

$$\begin{cases} L = A^* x^* \\ \|x^*\| \rightarrow \min \end{cases}$$

به جای کنار دستگاه روبرو به سمت می آید جواب منبم نرم گفته می شود زیرا نرم جواب (مجهولات)  $\min$  می شود.

نرم های متداول در سریانی: (نرم یک نابع اسکالر می باشد)

$$x_n = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix}$$

$$1) \|x\|_2 = \sqrt{x_1^2 + x_2^2 + \dots + x_n^2} \rightarrow \text{نرم اقلیدسی یا } L_2$$

$$2) \|x\|_1 = \sum_{i=1}^n |x_i| \rightarrow \text{نرم } L_1$$

$$3) \|x\|_\infty = \max_{i=1 \rightarrow n} |x_i| \rightarrow \text{نرم بی نهایت (حقیف)}$$

$$4) \|x\|_q = \sqrt[q]{|x_1|^q + |x_2|^q + \dots + |x_n|^q} \rightarrow \text{نرم } L_q$$

$\min$  شدن  $x^*$  دو مشکل اساسی دارد:

1- سمتی از  $x^*$  مجهولات واقعی هستند ( $x$ ) که هر مقداری را می توانند اختیار کنند و  $\min$  کردن آنها معنادار نیست. مثلاً در شبکده که مجهولات حقیقت هستند  $\min$  شدن حقیقت معنادار نیست.

2- با توجه به اینکه ما تا حدودی به مشاهدات انجام شده اطمینان داریم پس هر مقداری برای ما قابل قبول نیست و  $\min$  کردن  $\|x^*\|$  ممکن نیست. به نسبت شود  $\epsilon$  اعداد بزرگی شوند که برای ما قابل قبول نباشد.

اصحیح شده min کردن نرم:

$$\begin{cases} L = A^* x^* \\ \|y\| \rightarrow \min \\ \text{محدود است} \end{cases} \rightarrow \begin{cases} L_2 \rightarrow \text{جواب کمترین درجه} \\ L_1 \rightarrow \text{جواب پایدار} \\ L_\infty \rightarrow \text{نرم } L_\infty \end{cases}$$

هرگاه نرم مجهولات Min شود به آن می‌نرم می‌گویند. و اگر مجهولات min کنیم به آن کمترین درجه می‌گویند. در نرم کمترین درجه استفاده از نرم 2 می‌باشد ( $L_2$ ).

مزاای روش  $L_2$ :

1) اگر مشاهدات دارای انحراف خطای sys داشته باشند، همچنین از تابع توزیع نرمال تبعیت کنند، جوابهای حاصل از روش کمترین مربعات حاوی خصوصیات آماري است که تئوری تقریب فوق‌الذکر هم است.

2) در حالت دستگاه معادلات خطی و غیر خطی روش کمترین مربعات با تغییر جزئی قابل استفاده میباشد نسبت به دیگر روابط مورد نیاز برای تعیین مجهولات در حالت خطی و غیر خطی اختلاف جزئی دارند.

3) آسانی محاسبات

عیب روش  $L_2$ :

اگر مشاهدات دارای انحراف خطای sys داشته باشند، جواب حاصل رابعد است تحت تأثیر تغییر میدهند. (شدت عین خطا در این روش زیاد است)


مزاای روش  $L_1$ :

شدت عین خطا در این روش کمتر میباشد. به عبارت دیگر اگر مشاهداتی خطایی بیشتر باشد، اصحیح مربوط به آن مشاهد نیز بیشتر است. به همین دلیل روش  $L_1$  روش مناسبی برای کشف مشاهدات اشتباه میباشد. (مشاهدات اشتباه یا بیشترین روی جواب به صورت خلی است) عیب روش  $L_1$ :

1) خصوصیات آماري روش  $L_2$  (با حداقل بعضی از آنها را) نخواهد داشت.

2) روابط مورد نیاز برای حل مجهولات در حالت خطی و غیر خطی اختلاف زیادی باهم دارند.

3) پیچیدگی محاسبات.



1) روش  $L_1$  2) پردازشهای قبل از سرشکنی (از حیث وجود خطای sys و اشتباهات نرمال بودن و ...)



$$\begin{cases} A^* x^* = L \\ \|v\|_2 \rightarrow \min \end{cases} \xrightarrow{\text{برای } v} \|v\|_2^2 \rightarrow \min, \|v\|_2^2 = v^T v$$


$$\rightarrow \begin{cases} A^* x^* = L \\ \|v\|_2^2 = v^T v \rightarrow \min \end{cases}$$

دلیل استفاده از ماتریس وزن:

۱۱ منطق حکم می‌کند که داده‌ای که نقش بیشتری را دارد و صحت بیشتری بگیرد. این موضوع در تابع هدف لحاظ شده است. به این ترتیب  $v$  را روی تابع به یک میزان می‌بایست.

۱۲ نرم اقلیدسی یک بردار چیزی جز اندازه آن نمی‌باشد، در صورتی رابطه  $\|v\|_2^2 = \sum_{i=1}^n v_i^2$  اندازه را می‌دهد که متغیرات از هم مستقل باشند و نیز همبستگی آنها یک می‌باشد. در غیر این صورت تابع هدف باید تصحیح شود.

$$\|v\|_2^2 = s_1^2 v_1^2 + s_2^2 v_2^2 + \dots + s_n^2 v_n^2 + \sum_{j=1}^n \sum_{i=1, i \neq j}^n s_{ij} v_i v_j$$



$$d^2 s^2 = dx^2 + dy^2 + dz^2 \rightarrow \text{کارترتیب}$$

$$d^2 s^2 \neq dr^2 + d\theta^2 + d\lambda^2 \rightarrow \text{دکروی}$$

$$\Rightarrow d^2 s^2 = [dr d\theta d\lambda] G \begin{bmatrix} dr \\ d\theta \\ d\lambda \end{bmatrix}$$

G: ماتریس کوواریانس ضرایب را از این می‌برد و یک ماتریس معین مثبت می‌باشد. اگر رسم کنیم متغیرات متعامد باشند هم قطری است.

$$\|v\|_2^2 = v^T P v \quad P = \begin{bmatrix} s_1^2 & s_{12} & s_{13} & \dots & s_{1n} \\ s_{12} & s_2^2 & s_{23} & \dots & s_{2n} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ s_{n1} & s_{n2} & s_{n3} & \dots & s_n^2 \end{bmatrix}$$

میان جابجایی، ماتریس وزن می‌گویند که یک ماتریس  $P, D$  است. اگر متغیرات مستقل باشند ماتریس وزن یک ماتریس قطری است مثل اینکه محورها متعامدند. ثابت خواهیم کرد  $P \propto \Sigma_{LL}^{-1}$  (ماتریس واریانس کوواریانس متغیرات)

$$\begin{cases} A^* x^* = L \\ \|v\|_2^2 = v^T P v \end{cases} \equiv L_{n \times 1} + v_{n \times 1} = A_{n \times u} x_{u \times 1} \quad \left. \begin{array}{l} n > u \\ r(A) = u \end{array} \right\} \text{فرضیات}$$

روش اول:

$$L + v = Ax \rightarrow v = Ax - L \rightarrow v^T P v = (Ax - L)^T P (Ax - L) = (x^T A^T - L^T) P (Ax - L) = (x^T A^T P - L^T P) (Ax - L)$$

$$= x^T A^T P A x - x^T A^T P L - L^T P A x + L^T P L \Rightarrow v^T p v \rightarrow \min$$

$$\rightarrow \frac{\partial (v^T p v)}{\partial x} = 0 \rightarrow 2 x^T A^T P A - 2 L^T P A = 0 \rightarrow x^T A^T P A = L^T P A \rightarrow \text{از همین معادله ترانسپوز می گیریم}$$

$$A^T P A x = A^T P L \Rightarrow \begin{cases} \hat{x} = (A^T P A)^{-1} A^T P L \rightarrow \text{برآوردی از جواب واقعی} \\ \hat{y} = A \hat{x} - L \rightarrow \text{برآوردی از تصحیحات واقعی} \\ \hat{L} = L + \hat{y} \rightarrow \text{برآوردی از شرط حد واقعی} \end{cases}$$

$$\frac{\partial}{\partial x} \left( \frac{\partial (v^T p v)}{\partial x} \right) = \frac{\partial}{\partial x} (2 x^T A^T P A - 2 L^T P A) = 2 (A^T P A)^T = 2 A^T P A$$

ماتریس  $A^T P A$  یک ماتریس  $p.d$  است (چون  $p$  یک ماتریس  $p.d$  است و  $r(A) = u$  می باشد) بنابراین جواب بدست آمده  $\min$  کننده  $v^T p v$  است.

انواع مدل های سرشکنی:

انواع مدل های که در این درس مورد بررسی قرار میگیرند عبارتند از:

1- مدل پارامتریک

2- مدل ترکیبی

3- مدل شرط

4- مدل های ثانویه (این مدل گسترش های خاصی functional constraint

1) مدل گسترش های داخلی inner constraint

2) مدل گسترش های وزن دار weight constraint

انواع مدل از لحاظ تعداد شرط:

1- minimum constraint

2- over constraint

کلمه مدل های فوق می تواند خطی یا غیر خطی باشند

1- مدل پارامتریک:

اگر بتوان به ازای هر منفرجه یک معادله نوشت به گونه ای که رتبه ماتریس ضرایب مجهولات برابر تعداد مجهولات باشد یا به عبارت دیگر ماتریس ضرایب کامل ستونی باشد در این صورت مدل پارامتریک خواهیم داشت که میتواند خطی یا غیر خطی باشد.

مدل پارامتریک

$$\begin{cases} \hat{L}_{n \times 1} = A_{n \times u} \hat{x}_{u \times 1} \\ \hat{L}_{n \times 1} = f_{n \times 1}(\hat{x}_{u \times 1}) \end{cases}$$

تعداد مجهولات:  $u$   
تعداد مشاهدات:  $n$   
 $A$ : ماتریس ضرایب (طرح)

$r(A) = u$   
 $n \geq u$

- در مدل پارامتریک در هر معادله باید بیشتر از یک متغیر باشد

$$\begin{cases} \hat{L} = A \hat{x} \\ \hat{v}^T P \hat{v} \rightarrow \min \end{cases} \xrightarrow{\text{حساب رگرسیون}} \begin{cases} \hat{x} = (A^T P A)^{-1} A^T P L \\ \hat{v} = A \hat{x} - L = [A(A^T P A)^{-1} A^T P - I] L \\ \hat{L} = L + \hat{v} \end{cases}$$

ل در روابط فوق شامل متغیر ثابت و مشاهد می باشد.

①  $\Sigma_{\hat{x}\hat{x}} = J_{\hat{x}L} \Sigma_{LL} J_{\hat{x}L}^T = (A^T P A)^{-1} A^T P \Sigma_{LL} P A (A^T P A)^{-1}$  و  $P = \sigma_o^2 \Sigma_{LL}^{-1}$   
 $\rightarrow \Sigma_{\hat{x}\hat{x}} = \sigma_o^2 \underbrace{(A^T P A)^{-1} A^T P A (A^T P A)^{-1}}_{=I} = \sigma_o^2 (A^T P A)^{-1}$  و  $\Sigma_{\hat{x}\hat{x}} = \hat{\sigma}_o^2 (A^T P A)^{-1}$

②  $\Sigma_{\hat{v}\hat{v}} = J_{\hat{v}L} \Sigma_{LL} J_{\hat{v}L}^T = [A(A^T P A)^{-1} A^T P - I] \Sigma_{LL} [A(A^T P A)^{-1} A^T P - I]^T = \sigma_o^2 [A(A^T P A)^{-1} A^T P - I]^T \times$   
 $[P A (A^T P A)^{-1} A^T - I] = \sigma_o^2 \underbrace{[A(A^T P A)^{-1} (A^T P A) (A^T P A)^{-1} A^T - A(A^T P A)^{-1} A^T + P^{-1}]}_I = \sigma_o^2 [P^{-1} - A(A^T P A)^{-1} A^T]$   
 $\Sigma_{\hat{v}\hat{v}} = \hat{\sigma}_o^2 (P^{-1} - A(A^T P A)^{-1} A^T)$

③  $\Sigma_{\hat{L}\hat{L}} = J_{\hat{L}L} \Sigma_{LL} J_{\hat{L}L}^T = A(A^T P A)^{-1} A^T P \Sigma_{LL} P A (A^T P A)^{-1} A^T = \sigma_o^2 A(A^T P A)^{-1} A^T P P^{-1} P A (A^T P A)^{-1} A^T$   
 $= \sigma_o^2 A(A^T P A)^{-1} A^T \rightarrow \Sigma_{\hat{L}\hat{L}} = \sigma_o^2 A(A^T P A)^{-1} A^T$  و  $\Sigma_{\hat{L}\hat{L}} = \hat{\sigma}_o^2 A(A^T P A)^{-1} A^T$

بالمی دست می توان در رابطه که  $\Sigma_{\hat{L}\hat{L}} = \Sigma_{LL} - \Sigma_{\hat{v}\hat{v}}$

چرا با وجود رابطه  $\hat{L} = L + \hat{v}$  رابطه  $\Sigma_{\hat{L}\hat{L}} = \Sigma_{LL} - \Sigma_{\hat{v}\hat{v}}$  دارای علامت منفی است؟

$\hat{L} = L + \hat{v} \rightarrow \Sigma_{\hat{L}\hat{L}} = \Sigma_{LL} + \Sigma_{\hat{v}\hat{v}} + 2 \Sigma_{\hat{v}L}$  به دلیل وابستگی (کواریانس) متغیر بین مشاهدات و تصحیح

انجام شده  $\leftarrow \Sigma_{\hat{v}L} = \Sigma_{L\hat{v}} = -\Sigma_{\hat{v}\hat{v}}$

نتیجه:

df = تعداد مجهولات - تعداد معادلات + K



در مدل پارامتریک مقدار  $K=0$  است. به دلیل اینکه ماتریس ضرایب مجهولات مرتبه کامل سکوی است (رتبه ماتریس برابر تعداد مجهولات است)

در مدل پارامتریک  $df = n - u$

$$\hat{V} = A\hat{x} - L = [A(A^T P A)^{-1} A^T P - I]L = -RL \rightarrow R = I - A(A^T P A)^{-1} A^T P$$

ماتریس آزادی  $R = \sum_{\hat{V}} \sum_{\hat{L}}^{-1} = I - \sum_{\hat{L}} \sum_{\hat{L}}^{-1}$

عناصر روی قطر اصلی ماتریس آزادی را عدد آزادی گویند. متناظر با هرش هده یک عدد آزادی خواهیم داشت. ثابت می شود که عدد آزادی هر

ش هده  $1 \leq r_i \leq n$  است. و  $TR(R)$  که عبارت از  $tr = \sum_{i=1}^n r_i = df$  برابر عدد آزادی است.

مثال:

در مدل پارامتریک خطی اگر  $n = u$ ،  $\hat{V}$  چه مقدار خواهد شد؟

$$\hat{L}_{n \times 1} = A_{n \times n} x_{n \times 1} \rightarrow \begin{cases} \hat{x} = A^{-1} L \\ \hat{V} = 0 \\ \hat{L} = L \end{cases}$$

وقتی درجه آزادی صفر شود، بردار  $\hat{V}$  برابر صفر خواهد شد. مث هدهای  $\hat{V}$  صفر دارند که کنترلی روی آنها نباشد. در صورتی که تعداد مجهولات

برابر معادلات باشد جواب مشکل از ماتریس وزن است. به عبارت دیگر به ازای تمامی معادله وزن مجاز داریم:


$$\begin{cases} \hat{x} = (A^T P A)^{-1} A^T P L \\ \hat{V} = A\hat{x} - L \\ \hat{L} = L + \hat{V} \end{cases} \quad \begin{cases} \hat{x} = A^{-1} L \\ \hat{V} = 0 \\ \hat{L} = L \end{cases}$$

\*  $P$  می مجاز هستند که وارون پذیر بودن  $A^T P A$  را با مشکل روبرو نکنند.

مثال: اعلاقت مش هدهات یک است (وزن یک)

$$df = 3 - 2 = 1$$

مش هدهات دارای وزن یک نند  $P = I$



$$L_1 = 1 \text{ m}$$

$$L_2 = 2 \text{ m}$$

$$L_3 = -3.03 \text{ m}$$

$$h_A = 100$$

$$\hat{L}_1 = \hat{h}_B - h_A \rightarrow \hat{L}_1 + 100 = \hat{h}_B$$

$$\hat{L}_2 = \hat{h}_C - \hat{h}_B \rightarrow \hat{L}_2 = \hat{h}_C - \hat{h}_B$$

$$\hat{L}_3 = h_A - \hat{h}_C \rightarrow \hat{L}_3 - 100 = -\hat{h}_C$$

$$\rightarrow \text{بردار مش هدهات} = L = \begin{bmatrix} 101 \\ 2 \\ -103.03 \end{bmatrix}, A = \begin{bmatrix} 1 & 0 \\ -1 & 1 \\ 0 & -1 \end{bmatrix}$$

$$\rightarrow \hat{x} = (A^T P A)^{-1} A^T P L = \begin{bmatrix} 101.01 \\ 103.02 \end{bmatrix}$$

$$\hat{v} = A\hat{x} - L = \begin{bmatrix} 0.01 \\ 0.01 \\ 0.01 \end{bmatrix}$$


$$\hat{\sigma}_0^2 = \frac{\hat{v}^T P \hat{v}}{df} = 0.0003$$

$$\hat{L} = L + \hat{v} = \begin{bmatrix} 1.01 \\ 2.01 \\ -3.02 \end{bmatrix}$$

با ابراحلات ارتفاع مناسب با طول کارهای باشد.

$$P = \sigma_0^2 \Sigma_{LL}^{-1}, \quad \Sigma_{LL} = \begin{bmatrix} \sigma_0^2 L_1^2 & 0 & 0 \\ 0 & \sigma_0^2 L_2^2 & 0 \\ 0 & 0 & \sigma_0^2 L_3^2 \end{bmatrix} = K^2 \begin{bmatrix} L_{AB}^2 & 0 & 0 \\ 0 & L_{BC}^2 & 0 \\ 0 & 0 & L_{AC}^2 \end{bmatrix} \rightarrow \Sigma_{LL}^{-1} = \frac{1}{K^2} \begin{bmatrix} \frac{1}{L_{AB}^2} & 0 & 0 \\ 0 & \frac{1}{L_{BC}^2} & 0 \\ 0 & 0 & \frac{1}{L_{AC}^2} \end{bmatrix}$$

مثال:



$$L_1 = 1m$$

$$L_2 = 2m$$

$$L_3 = -3.03m$$

$$L_4 = 4m$$

$$h_A = 100m$$

\* درجه آزادی در هیچ شکلهای صفتی نمی شود و همیشه بزرگتر یا مساوی صفر است. ( $df \geq 0$ )

$$df_n = \frac{n(n+1)}{2} - (n+1)$$

مدل پارامتریک غیر خطی:

اگر مدل های سرشتی از این نوعند. فرم کلی این مدلها به صورت  $\hat{L} = f(\hat{x})$  می باشد.

$$\begin{cases} \hat{L}_{n \times 1} = L_{n \times 1} + \hat{v}_{n \times 1} = f(\hat{x}) \\ \hat{v}^T P \hat{v} \rightarrow \text{Min} \end{cases}$$

یکی از روش های حل مسئله خطی کردن مدل  $\hat{L} = f(\hat{x})$  می باشد. بنابراین برای خطی کردن نیازمند ادراک برای محمولات می باشیم. این مقدار ادراک  $x_0$  می نامیم.

$$\hat{L} = f(\hat{x}) \xrightarrow{\text{خطی کنیم}} \hat{L} = f(x_0) + \left. \frac{\partial f}{\partial \hat{x}} \right|_{\hat{x}=x_0} (\hat{x} - x_0) \quad \text{I} \quad \text{و} \quad f(x_0) = L_{n \times 1}^c \quad (\text{مقدار محاسبه شده})$$

$$\text{فرض} \rightarrow \left. \frac{\partial f}{\partial \hat{x}} \right|_{\hat{x}=x_0} = A_{n \times u}, \quad \delta \hat{L}_{n \times 1} = \hat{L} - f(x_0) = L - L^c, \quad \hat{x} - x_0 = \delta \hat{x}_{n \times u}$$

$$\hat{L} - f(x_0) = \left. \frac{\partial f}{\partial \hat{x}} \right|_{\hat{x}=x_0} (\hat{x} - x_0) \rightarrow \text{II} \quad \delta \hat{L} = A \delta \hat{x} \rightarrow \delta L + \hat{v} = A \delta \hat{x}$$

$$\rightarrow \begin{cases} \delta \hat{L} = \delta L + \hat{v} = A_{n \times u} \delta \hat{x} \\ \hat{v}^T P \hat{v} \rightarrow \text{min} \end{cases}$$

$$\begin{cases} \delta \hat{L} = A_{n \times u} \delta \hat{x} \\ \hat{V}^T P \hat{V} \rightarrow \min \end{cases} \xrightarrow{\substack{\text{با توجه به مدل} \\ \text{پارامترهای خطی}}} \delta \hat{x} = (A^T P A)^{-1} A^T P \delta L$$

$$\rightarrow \hat{V} = A \delta \hat{x} - \delta L$$

$$\rightarrow \hat{L} = L + \hat{V} = A \delta \hat{x} + L - \delta L = A \delta \hat{x} + L^c$$

$$\Rightarrow \hat{x} = x_0 + \delta \hat{x}$$

①  $\sum_{\delta \hat{x} \delta \hat{x}} = \sum_{\hat{x} \hat{x}} = \delta \delta^T \delta L \sum_{\delta L \delta L} \delta \delta^T \delta L = (A^T P A)^{-1} A^T P \sum_{\delta L \delta L} P A (A^T P A)^{-1}$  ،  $\sum_{\delta L \delta L} = \sum_{LL}$

$$= \sigma_0^2 P^{-1} \rightarrow \sum_{\delta \hat{x} \delta \hat{x}} = \sigma_0^2 (A^T P A)^{-1} A^T P A (A^T P A)^{-1} = \sigma_0^2 (A^T P A)^{-1}$$

②  $\sum_{\hat{V} \hat{V}} = \sigma_0^2 (P^{-1} - A (A^T P A)^{-1} A^T)$

③  $\sum_{\hat{L} \hat{L}} = \sigma_0^2 A (A^T P A)^{-1} A^T$  ،  $\sum_{\hat{L} \hat{L}} = \sum_{LL} - \sum_{\hat{V} \hat{V}}$  برای بدست آوردن ماتریس  $\hat{L}$  برآورد  $\hat{L}$  را به  $\hat{L}$  تبدیل می کنیم.

درجه آزادی:  $df = k - \text{مجهولات} - \text{معادلات}$

$$\frac{\sigma_0^2}{df} = \frac{\hat{V}^T P \hat{V}}{df}$$

مقدار  $k$  در این مدل نیز به دلیل اینکه  $r(A) = u$  برابر صفر نیست.


روند تکرار:

با استفاده از روشی که معلوم شود  $\hat{x} = \delta \hat{x} + x_0 \leftarrow \hat{x}_{\text{new}} = x_0$  دوباره مدرسه شگنی

له تغییرات در  $\delta L$  و  $A$

انواع مشاهدات:

۱) طول: منحنی که مختصات نقطه  $i$  و  $j$  مجهول باشد و طول بین آنها مشخص شده است.



$$\rightarrow \hat{L}_{ij} = \sqrt{(\hat{x}_j - \hat{x}_i)^2 + (\hat{y}_j - \hat{y}_i)^2}$$

$$x_0 = \begin{bmatrix} x_{0,i} \\ y_{0,i} \\ x_{0,j} \\ y_{0,j} \end{bmatrix}$$

$$\frac{\partial L_{ij}}{\partial \hat{x}_i} \bigg|_{\hat{x}=x_0} = \frac{-(x_{0,j} - x_{0,i})}{\sqrt{(x_{0,j} - x_{0,i})^2 + (y_{0,j} - y_{0,i})^2}} = \frac{-(x_{0,j} - x_{0,i})}{L_{ij_0}}$$


$$\frac{\partial L_{ij}}{\partial \hat{y}_i} \bigg|_{\hat{x}=x_0} = ?$$

$$\frac{\partial L_{ij}}{\partial \hat{x}_j} \bigg|_{\hat{x}=x_0} = ?$$

$$\frac{\partial L_{ij}}{\partial \hat{y}_j} \bigg|_{\hat{x}=x_0} = ?$$

به هم بطریق مشابیه می آیند  $\leftarrow$

2) آزیموت: مختصات ناوی و محوریت استاندارد را مشخص شده است.




$$\hat{A}z = \tan^{-1} \frac{\hat{x}_j - \hat{x}_i}{\hat{y}_j - \hat{y}_i} \pm k\pi, \quad x_0 = \begin{bmatrix} x_{0i} \\ y_{0i} \\ x_{0j} \\ y_{0j} \end{bmatrix} \rightarrow \text{مختصات مبادیه‌ها}$$

ترتیب باشند

$$\frac{\partial \hat{A}z}{\partial \hat{x}_i} = \frac{-(y_{0j} - y_{0i})}{(x_{0j} - x_{0i})^2 + (y_{0j} - y_{0i})^2} = \frac{-(y_{0j} - y_{0i})}{L_{ij}^2}$$


3) زاویه: فرض کنید مختصات خط ناوی و K محوریت است و زاویه بین آنها ثابت شده است.



$$\hat{\alpha} = \tan^{-1} \frac{\hat{x}_k - \hat{x}_i}{\hat{y}_k - \hat{y}_i} - \tan^{-1} \frac{\hat{x}_j - \hat{x}_i}{\hat{y}_j - \hat{y}_i} \pm k\pi$$

$$x_0 = [x_{0i} \ y_{0i} \ x_{0j} \ y_{0j} \ x_{0k} \ y_{0k}]^T$$


4) استاندارد: مختصات ناوی و محوریت استاندارد مشخص شده است.



$$\hat{d}_{ij} = \hat{A}z_{ij} + \hat{\Omega}_0 \pm k\pi$$

مثال:

طول و آزیموت AB و مختصات A معلوم است. نوشتن معادلات درجه آزادی مطلوب کنید.



۱۴ معادله و ۶ محوریت مختصات و ۴ تا  $\Omega_0$  به ازای ۴ استیج

$$df = 14 - 6 - 4 = 4$$

$$\hat{L}_1 = \tan^{-1} \frac{\hat{x}_B - \hat{x}_A}{\hat{y}_B - \hat{y}_A} \pm k\pi$$

$$\hat{L}_2 = \sqrt{(\hat{x}_B - \hat{x}_A)^2 + (\hat{y}_B - \hat{y}_A)^2}$$

$$\hat{L}_3 = \tan^{-1} \frac{\hat{x}_B - \hat{x}_A}{\hat{y}_B - \hat{y}_A} + \hat{\Omega}_0 \pm k\pi$$

$$\hat{L}_4 = \dots$$


$$\hat{L}_5 = \dots$$

$$\vdots$$

$$\hat{L}_{14} = \dots$$



برای تعیین مختصات نقطه P از چهار نقطه A, B, C, D مشاهدات به صورت زیر انجام شده است. در صورتی که مشاهدات مستقل و با خطای معیار 5" اندازه گیری شده باشند، مختصات صحیح شده و فاکتور وارایش را بنویسید.



$$A (6091.13, 3631.61)$$

$$B (5973.88, 1561)$$

$$C (6947.21, 178.43)$$

$$D (7597.31, 2063.49)$$

$$L_1 = 126^\circ 8' 26''$$

$$L_3 = 11^\circ 13' 10''$$

$$L_2 = 53^\circ 22' 37''$$

$$L_4 = 344^\circ 41' 38''$$

تبدیل به رادیان  $\rightarrow L_1 = 2.201 \quad L_2 = 0.931 \quad L_3 = 0.195 \quad L_4 = 6.016$

$$df = 4 - 2 = 2 \rightarrow \begin{cases} x_{0P} = 7437 \\ y_{0P} = 2648 \end{cases}$$

$$\hat{L}_1 = \tan^{-1} \frac{\hat{x}_P - x_A}{\hat{y}_P - y_A} \pm K\pi$$

$$\hat{L}_3 = \tan^{-1} \frac{\hat{x}_P - x_C}{\hat{y}_P - y_C} \pm K\pi$$

$$\hat{L}_2 = \tan^{-1} \frac{\hat{x}_P - x_B}{\hat{y}_P - y_B} \pm K\pi$$

$$\hat{L}_4 = \tan^{-1} \frac{\hat{x}_P - x_D}{\hat{y}_P - y_D} \pm K\pi$$

$$\delta \hat{x} = (A^T P A)^{-1} A^T P \delta L, \quad P = \delta L^2 \sum_{LL}^{-1} = \begin{bmatrix} \frac{1}{25} & 0 & 0 & 0 \\ 0 & \frac{1}{25} & 0 & 0 \\ 0 & 0 & \frac{1}{25} & 0 \\ 0 & 0 & 0 & \frac{1}{25} \end{bmatrix}, \quad \delta L = L - \hat{L}^C = \begin{bmatrix} 1.35 \\ -1.23 \\ 1026 \\ 1.53 \end{bmatrix} \times 10^{-3} \text{ rad}$$

$$\hat{V} = A \delta \hat{x} - \delta L$$

$$A = 10 \times \begin{bmatrix} -35 & -48 \\ 32 & -44 \\ 28 & -7 \\ 159 & 43 \end{bmatrix}$$

$$\delta \hat{x} = \begin{bmatrix} 1.67 \\ 1.633 \end{bmatrix}$$

$$\hat{x} = x_0 + \delta \hat{x} = \begin{bmatrix} 7437.167 \\ 2648.623 \end{bmatrix}$$

$$\hat{V} = 10 \times \begin{bmatrix} -0.097 \\ 0.105 \\ -0.098 \\ -0.019 \end{bmatrix}$$

مدل ترکیبی:

اگر بتوان از آزادی حرکت هر یک معادله نسبت به عبارت دیگر اگر معادلات نسبت به مجهولات صریح باشند نسبت به آنها

$$A \hat{x} + B \hat{L} + W = 0 \quad \text{خطی}$$

$$\rightarrow A_{r \times u}, \hat{x}_{u \times 1}, B_{r \times n}, \hat{L}_{n \times 1}, W_{r \times 1}$$

در اختیارات مدل ترکیبی خواهیم داشت

$$f(\hat{x}, \hat{L}) = 0 \quad \text{غیر خطی}$$

$$\rightarrow f_{r \times 1}, \quad u \leq r \leq n$$

حل:

$$\begin{cases} f(\hat{x}, \hat{L}) = 0 \\ \hat{v}^T p \hat{v} \rightarrow \min \end{cases}$$

یکی از روشهای حل مسئله خطی کردن معادله  $f(\hat{x}, \hat{L})$  میباشد. بدلیل اینکه این معادله نسبت به مجهولات و نسبت به متغیرهای  $\hat{x}$  و  $\hat{L}$  غیرخطی میباشد. بنابراین معادله را درجه اول برای مجهولات و متغیرهای  $\hat{x}$  و  $\hat{L}$  داریم. این معادله را با  $(x_0, L_0)$  نمایش میدهیم. بهترین معادله برای  $L$  همان معادله  $\hat{L}$  میباشد.

$$f(\hat{x}, \hat{L}) = f(x_0, L_0) + \left. \frac{\partial f}{\partial \hat{x}} \right|_{(\hat{x}, \hat{L})=(x_0, L_0)} (\hat{x} - x_0) + \left. \frac{\partial f}{\partial \hat{L}} \right|_{(\hat{x}, \hat{L})=(x_0, L_0)} (\hat{L} - L_0)$$

$$\text{فرض } f(x_0, L_0) = w_{r \times 1}, \quad \frac{\partial f}{\partial \hat{x}} = A_{r \times n}, \quad \frac{\partial f}{\partial \hat{L}} = B_{r \times n}, \quad \hat{x} - x_0 = \delta \hat{x}, \quad \hat{L} - L_0 = \hat{v}$$

$$\rightarrow \begin{cases} A \delta \hat{x} + B \hat{v} + w = 0 \\ \hat{v}^T p \hat{v} \rightarrow \min \end{cases} \quad \begin{cases} r(A) = n \\ r(B) = r = \text{همواره برابری باشد} \end{cases}$$

یکی از روشهای حل این مسئله روش لگرانژی میباشد.

$$\Phi = \hat{v}^T p \hat{v} - 2 \lambda^T (A \delta \hat{x} + B \hat{v} + w) \Rightarrow \min$$

$$\frac{\partial \Phi}{\partial \hat{v}} = 2 \hat{v}^T p - 2 \lambda^T B = 0$$

$$\textcircled{1} p \hat{v} - B^T \lambda = 0$$

معادله n

$$\lambda_{r \times 1}$$

$$\frac{\partial \Phi}{\partial \delta \hat{x}} = -2 \lambda^T A = 0$$

برای استخراج  
از معادله

$$\textcircled{2} A^T \lambda = 0$$

معادله u

$$\hat{v}_{n \times 1}$$

$$\textcircled{3} A \delta \hat{x} + B \hat{v} + w = 0$$

معادله r

$$(\delta \hat{x})_{u \times 1}$$

$$\frac{\partial \Phi}{\partial \lambda} = -2 (A \delta \hat{x} + B \hat{v} + w)^T = 0$$

$$r+n+u = \text{تعداد مجهولات}$$

$$r+n+u = \text{تعداد معادلات}$$

برای حل دستگاه فوق از روش جایگزینی مستقیم استفاده می کنیم.

$$\textcircled{1} \rightarrow \hat{v} = p^{-1} B^T \lambda \textcircled{4}$$

$$\textcircled{4} \rightarrow \textcircled{3} \Rightarrow A \delta \hat{x} + B(p^{-1} B^T \lambda) + w = 0 \Rightarrow \lambda = -(B p^{-1} B^T)^{-1} (A \delta \hat{x} + w) = -\tilde{M}^{-1} (A \delta \hat{x} + w) \textcircled{5}$$

$$\textcircled{5} \rightarrow \textcircled{2} \Rightarrow -A^T \tilde{M}^{-1} A \delta \hat{x} - A^T \tilde{M}^{-1} w = 0 \rightarrow \delta \hat{x} = -(A^T \tilde{M}^{-1} A)^{-1} A^T \tilde{M}^{-1} w$$

$$w = f(x_0, L_0)$$

$$\delta \hat{x} = \hat{x} - x_0$$

$$\hat{v} = \hat{L} - L_0$$

$$\lambda = -\bar{M}^{-1} (A \delta \hat{x} + w) = -\bar{M}^{-1} (-A(A^T \bar{M}^{-1} A)^{-1} A^T \bar{M}^{-1} w + w) = -\bar{M}^{-1} (I - A(A^T \bar{M}^{-1} A)^{-1} A^T \bar{M}^{-1}) w$$

$$\hat{v} = \bar{P}^{-1} B^T \lambda = -\bar{P}^{-1} B^T \bar{M}^{-1} (I - A(A^T \bar{M}^{-1} A)^{-1} A^T \bar{M}^{-1}) w$$

$$\Sigma_{\delta \hat{x} \delta \hat{x}} = \Sigma_{\hat{x} \hat{x}} = \dot{J}_{\delta \hat{x} w} \Sigma_{ww} \dot{J}_{\delta \hat{x} w}^T = -(A^T \bar{M}^{-1} A)^{-1} A^T \bar{M}^{-1} \Sigma_{ww} (-\bar{M}^{-1} A (A^T \bar{M}^{-1} A)^{-1})$$

$$w = f(x_0, L) \rightarrow \Sigma_{ww} = \frac{\partial f}{\partial L} \Sigma_{LL} \frac{\partial f}{\partial L}^T = B \Sigma_{LL} B^T = \delta_L^2 B P^{-1} B^T = \delta_L^2 M$$

$$\Rightarrow \Sigma_{\delta \hat{x} \delta \hat{x}} = \delta_L^2 (A^T \bar{M}^{-1} A)^{-1} A^T \bar{M}^{-1} M \bar{M}^{-1} A (A^T \bar{M}^{-1} A)^{-1} = \delta_L^2 (A^T \bar{M}^{-1} A)^{-1}$$

$$\Sigma_{\hat{v} \hat{v}} = ? , \Sigma_{\hat{L} \hat{L}} = ? , \Sigma_{\hat{L} \hat{L}} = \Sigma_{LL} - \Sigma_{\hat{v} \hat{v}}$$

در این صورت مدل ترکیبی تبدیل به یک اسکالر عرضی می‌شود:

$$\delta \hat{L} = A \delta \hat{x} \rightarrow A \delta \hat{x} - \delta \hat{L} = 0 \rightarrow A \delta \hat{x} - \hat{v} - \delta_L = 0 \rightarrow \begin{cases} B = -I \\ w = -\delta_L \end{cases}$$

$$df = \text{مقدار محوولات} - \text{مقدار محولات} + K = r - u + 0 = r - u$$

$$K \leftarrow r(A) = u$$

$$\hat{B}_0^2 = \frac{\hat{v}^T P \hat{v}}{df} = \frac{\hat{v}^T P \hat{v}}{r - u}$$

$$\delta \hat{x} \rightarrow \hat{x} = x_0 + \delta \hat{x} \rightarrow x_0^{new} = \hat{x}$$

اگر مدل ترکیبی  $f(\hat{x}, \hat{L}) = 0$  حول نقطه  $(x_0, L)$  - مقدار شهادت و مقدار اولیه محوولات - خطی شده باشد، نزدیکی برای update کردن شهادت نسبت به شهادت را در روند تکمیل در حالت می‌دهیم.

1)  $\hat{L}$  (شهادت) به  $\hat{x}$  (محوولات) وابسته اند پس در حالت دادن یکی کافی است.

2) با توجه به اینکه تابع  $\hat{v}^T P \hat{v}$  مینیمم می‌شود، حد درجهایی نزدیک به  $\hat{L}$  می‌باشند و با توجه به اینکه  $\hat{L}$  نقطه همگرایی محولات هستند بنابراین خطی کردن حول یک فاصله دینفراسیلی صورت می‌گیرد. بنابراین نیازی به تکرار ندارند.

3) اگر شهادت را update کنیم نیاز به بازبینی وزن جدید است که این خود مشکل است.

4) هدف ما تعیین محوولات است با توجه به شهادت اصلی و چون تغییر شهادت شده را تغییر می‌دهد، هدف برآورده نخواهد شد، یعنی

ساختگی  
من خواهم نمود مرتب شد. انقدر هم  
در مدل پارامتریک خطی:

$$\Sigma_{\hat{L}\hat{L}} = \delta_o^2 \underbrace{A(A^T P A)^{-1} A^T}_{P.D}$$

if  $n > u \rightarrow \Sigma_{\hat{L}\hat{L}}$  is singular

$$r(\Sigma_{\hat{L}\hat{L}}) = r(A) = u < n$$

if  $n = u \rightarrow \Sigma_{\hat{L}\hat{L}}$  is not singular ممکن است وارون پذیر باشد

$\Sigma_{\hat{V}\hat{V}} \rightarrow$  singular صفر

$$E\left(\frac{\hat{V}^T P \hat{V}}{r-u}\right) = \delta_o^2 \quad \text{مغایم ثابت کنیم}$$

$$\hat{V} = \bar{P}^{-1} B^T \lambda = -\bar{P}^{-1} B^T \bar{M}^{-1} (I - A(A^T \bar{M}^{-1} A)^{-1} A^T \bar{M}^{-1}) w$$

$$\rightarrow \hat{V}^T P \hat{V} = w^T (I - \bar{M}^{-1} A(A^T \bar{M}^{-1} A)^{-1} A^T) \bar{M}^{-1} B \bar{P}^{-1} \underbrace{P \bar{P}^{-1}}_I B^T \bar{M}^{-1} (I - A(A^T \bar{M}^{-1} A)^{-1} A^T \bar{M}^{-1}) w =$$

$$w^T (I - \bar{M}^{-1} A(A^T \bar{M}^{-1} A)^{-1} A^T) \bar{M}^{-1} (I - A(A^T \bar{M}^{-1} A)^{-1} A^T \bar{M}^{-1}) w = w^T [\bar{M}^{-1} - \bar{M}^{-1} A(A^T \bar{M}^{-1} A)^{-1} A^T \bar{M}^{-1} -$$

$$\bar{M}^{-1} A(A^T \bar{M}^{-1} A)^{-1} A^T \bar{M}^{-1} + \bar{M}^{-1} A \underbrace{(A^T \bar{M}^{-1} A)^{-1} A^T \bar{M}^{-1} A(A^T \bar{M}^{-1} A)^{-1} A^T \bar{M}^{-1}}_I] w =$$

$$w^T [\bar{M}^{-1} - \bar{M}^{-1} A(A^T \bar{M}^{-1} A)^{-1} A^T \bar{M}^{-1}] w$$

$$\Rightarrow \text{Tr}(\hat{V}^T P \hat{V}) = \hat{V}^T P \hat{V} = \text{Tr}[w^T (\bar{M}^{-1} - \bar{M}^{-1} A(A^T \bar{M}^{-1} A)^{-1} A^T \bar{M}^{-1}) w] = \text{Tr}[(\bar{M}^{-1} - \bar{M}^{-1} A(A^T \bar{M}^{-1} A)^{-1} A^T \bar{M}^{-1}) w w^T] \Rightarrow$$

$$\text{استواری از طریق} \Rightarrow E(\hat{V}^T P \hat{V}) = \text{Tr}[E[(\bar{M}^{-1} - \bar{M}^{-1} A(A^T \bar{M}^{-1} A)^{-1} A^T \bar{M}^{-1}) w w^T]] = \text{Tr}[(\bar{M}^{-1} - \bar{M}^{-1} A(A^T \bar{M}^{-1} A)^{-1} A^T \bar{M}^{-1}) E(w w^T)] \quad \text{①}$$

$$* \Sigma_{ww} = E[(w - E(w))(w - E(w))^T] = E(w w^T) - E(w)E(w^T)$$

$$\rightarrow \begin{cases} E(w w^T) = \Sigma_{ww} + E(w)E(w^T) \\ \Sigma_{ww} = \delta_o^2 M \end{cases}$$

$$A \delta_{\hat{x}} + B \hat{V} + w = 0 \rightarrow E(A \delta_{\hat{x}} + B \hat{V} + w) = A E(\delta_{\hat{x}}) + B E(\hat{V}) + E(w) = 0 \rightarrow A \delta_x + 0 + E(w) = 0$$

$$\rightarrow E(w) = -A \delta_x^* \quad , \rightarrow E(w^T) = -\delta_x^T A^T$$


نتیج بدست آمده را در معادله ① جایگذاری کنیم



$$E[\hat{V}^T P \hat{V}] = \text{Tr} \left[ [(\bar{M}^{-1} - \bar{M}^{-1} A (A^T \bar{M}^{-1} A)^{-1} A^T \bar{M}^{-1}) (\delta_o^2 M + A \delta_x \delta_x^T A^T)] \right] = \text{Tr} \left[ \delta_o^2 \frac{(\bar{M}^{-1} M)}{I} - \delta_o^2 \bar{M}^{-1} A (A^T \bar{M}^{-1} A)^{-1} A^T \bar{M}^{-1} M \right. \\ \left. + \bar{M}^{-1} A \delta_x \delta_x^T A^T - \bar{M}^{-1} A (A^T \bar{M}^{-1} A)^{-1} A^T \bar{M}^{-1} A \delta_x \delta_x^T A^T \right] = \delta_o^2 \text{Tr}(\bar{M}^{-1} M) - \delta_o^2 \text{Tr}(\bar{M}^{-1} A (A^T \bar{M}^{-1} A)^{-1} A^T) = \\ \delta_o^2 r - \delta_o^2 \text{Tr}((A^T \bar{M}^{-1} A)^{-1} A^T \bar{M}^{-1} A) = \delta_o^2 (r - u) \rightarrow E(\hat{V}^T P \hat{V}) = \delta_o^2 (r - u) \rightarrow E\left(\frac{\hat{V}^T P \hat{V}}{r - u}\right) = \delta_o^2$$

مثال:

شکل زیر حالت ساده‌ای از فتوگرامتری زمینی را نشان می‌دهد که از سه ایستگاه  $S_1, S_2, S_3$  سه عکس از شیئی مورد نظر گرفته شده است. (ایستگاه‌ها طوری انتخاب شده‌اند که روی خط مستقیم قرار ندارند و در یک میانه هم و عمود بر ایستگاه‌گذاری زمین شود). برای تعیین مختصات نقطه‌ای مانند  $P$  مشاهدات زیر انجام شده‌اند. در صورتی که فاصله کانونی دوربین  $f = 100 \text{ mm}$  باشد مطلوب است مختصات  $P$  در سه مختصات  $x, y, z$  (مختصات مستقیم).



$$f = 100 \text{ mm}$$

$$L_1 = 16.5 \pm 0.1 \text{ mm}$$

$$L_2 = 3.8 \pm 0.1 \text{ mm}$$

$$L_3 = 20.4 \pm 0.1 \text{ mm}$$

$$L_4 = 10 \text{ m} \pm 5 \text{ cm}$$

$$L_5 = 8 \text{ m} \pm 5 \text{ cm}$$

حل: با استفاده از خالص

$$\frac{\hat{L}_1}{\hat{x}} = \frac{f}{\hat{y}} \rightarrow \hat{L}_1 \hat{y} - f \hat{x} = 0$$

$$\frac{\hat{L}_2}{\hat{L}_4 - \hat{x}} = \frac{f}{\hat{y}} \rightarrow \hat{L}_2 \hat{y} - \hat{L}_4 f + f \hat{x} = 0$$

$$\frac{\hat{L}_3}{\hat{L}_4 + \hat{L}_5 - \hat{x}} = \frac{f}{\hat{y}} \rightarrow \hat{L}_3 \hat{y} - f \hat{L}_4 - f \hat{L}_5 + f \hat{x} = 0$$

$$L = \begin{bmatrix} \hat{L}_1 \\ \hat{L}_2 \\ \hat{L}_3 \\ \hat{L}_4 \\ \hat{L}_5 \end{bmatrix}, \quad x = \begin{bmatrix} \hat{x} \\ \hat{y} \end{bmatrix}$$

$$\rightarrow \delta \hat{x} = -(A^T M A)^{-1} A^T M^{-1} W, \quad P = \delta_o^2 \sum_{LL}^{-1} = \text{diag} \left( \frac{1}{112}, \frac{1}{112}, \frac{1}{112}, \frac{1}{50^2}, \frac{1}{150^2} \right)$$

$$B = \frac{\partial f}{\partial \hat{L}} \bigg|_{\hat{x} = x_0, \hat{L} = L}, \quad A = \frac{\partial f}{\partial \hat{x}} \bigg|_{\hat{x} = x_0, \hat{L} = L}$$

$$\rightarrow \begin{cases} y_0 = \frac{f L_4}{L_1 + L_2} = \frac{100 \times 10000}{20.3} \approx 50000 \\ x_0 = \frac{L_1 y_0}{f} = 8250 \end{cases}$$

$$w = f(x_0, L) = \begin{bmatrix} L_1 y_0 - f(x_0) \\ L_2 y_0 - fL_4 + f x_0 \\ L_3 y_0 - fL_5 - fL_4 + f x_0 \end{bmatrix}_{3 \times 1 = r \times 1}$$

انواع مجهولات :

1- مجهولات قابل برآورد Estimatable

2- مجهولات غیر قابل برآورد in Estimatable


1- مجهولاتی هستند که با استفاده از مدل ریاضی و معادلات آن به دست می آید بدون اینکه نیاز به تعریف دقیق یا کمیت دیگر باشد. قابل برآورد به صورت ترکیب خطی از مشاهدات می توانند نوشته شوند. مثلاً در مدل های پارامتریک در ترکیب مجهولات قابل برآورد هستند.

$$\hat{L} = A\hat{x} \rightarrow \hat{x} = (A^T P A)^{-1} A^T P L$$

2- مجهولاتی هستند که با استفاده از مدل ریاضی و معادلات آن قابل برآورد نیستند و نیاز به تعریف دیگری از کمیت یا متغیر دیگر هستند. مجهولات را بدست آوردن کمیتی که باعث می شود که در یک مدل ریاضی مجهولات غیر قابل برآورد داشته باشیم defect می باشد که انواع آن به شرح زیر می باشد :


1- datum defect : (d. defect)

اگر برای شبکه ای با توجه به مجهولات سیستم محففات تعریف شده باشد در آن شبکه مجهولات غیر قابل برآورد خواهیم داشت. به عبارت دیگر عدم تعریف سیستم محففات برای شبکه، شبکه را دچار defect خواهد کرد.



$$d. defect = 1$$

برای آن سیستم ارتفاعی تعریف شده و اگر داده می تواند به بالا و پایین حرکت کند. برای رفع این مشکل لازم است ارتفاع یک نقطه را داشته باشیم.



$$datum defect = 1$$

برای این سیستم محففات تحت تعریف شده است.

اگر شبکه ها دو بعدی و مجهولات محففات باشند نیاز به ۲ پارامتر داریم :


- 1- انتقال x
- 2- انتقال y
- 3) انتقال مقیاس
- 4- دوران

اگر شبکه ما ارتفاعی باشد نیاز به برش یک پارامتر است  $\leftarrow$  انتقال 2

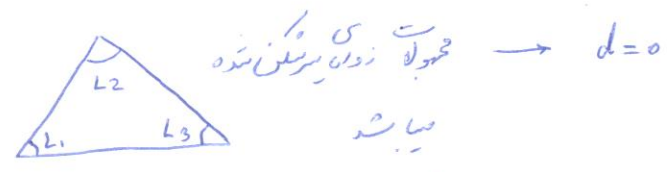
اگر شبکه ما 3 بعدی باشد و مجهولات محقق است، نیاز به برش 7 پارامتر داریم:

- 1- انتقال x      4- دوران x      7- محقق
- 2- انتقال y      5- دوران y
- 3- انتقال z      6- دوران z

عدد پارامترهای لازم برای تعریف سیستم محقق (عدد متغیر)، عدد  $d = \text{defect}$  شبکه را نشان میدهد و اگر با  $d$  نشان میدهند.



- محقق = 0
- دوران = 1
- انتقال = 2



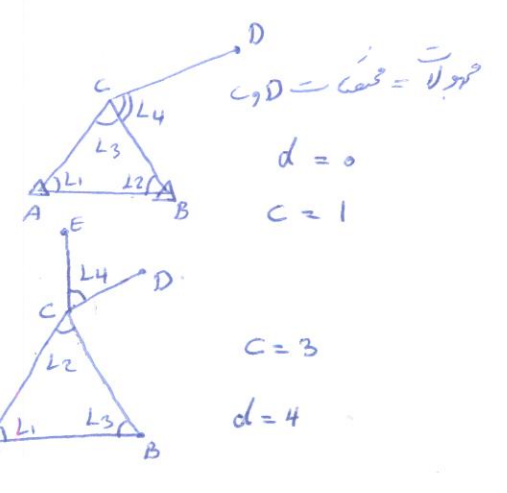
درصفت defect هایی را در شبکه در نظر بگیریم که روی مجهولات ما تأثیر ندارند از نظر ریاضی ما وجود defect داریم:

$$r(A) = r(A^T P A) = r(A^T M^{-1} A) = U - d$$

مدل ترکیبی
پارامترهای غیر خطی
پارامترهای خطی

2- configuration defect (c.defect):

اگر مثل شبکه با توصیف هندسه ثابت باشد به عبارت دیگر تغییر مثل دهد، شبکه دچار c.defect خواهد بود. در شبکه ای که دچار defect c هستند عدد برای حل تمام مجهولات کافی نیست. در شبکه ای که c دارد مجهولات غیر قابل برآورد خواهیم داشت. عدد پارامترهای لازم برای ثابت کردن شبکه عدد c.defect خواهد بود و با c نمایش میدهند.



حذف می کنیم محقق است  $\rightarrow$





مدل شرط:

اگر هدف در شبکه محاسبه شد حداثه برآورده شده  $(\hat{L})$  باشد، می‌توانیم به جای اینکه ابتدا از  $\hat{x}(\delta \hat{x})$  استفاده کنیم و پس از آن رابدهت بگیریم، به طور مستقیم  $\hat{L}$  را بدست آوریم. مدلی که برای این منظور استفاده می‌شود، مدل شرط نامیده می‌شود. مدلی که فقط بین مدلهای حداثه است و هیچگونه مجهولی در آن به کار نرفته است.

یک حسن دیگری که این مدل دارد این است که برای تعیین  $\hat{L}$  اگر شبکه ای دچار defect باشد دیگر نیازی نیست  $\delta \hat{x}$  را بدست آوریم و لذا می‌توانیم  $\hat{L}$  را محاسبه کنیم و می‌توانیم به آنکه مدل شرط هیچ مجهولی در آن به کار نرفته است، نیاز به  $\delta \hat{x}$  datum (مجموعه مقدمات) ندارد. لذا d-defect نخواهد داشت (d.d برای این مدل معنا ندارد).  
مدل شرط می‌تواند خطی یا غیر خطی باشد:

$$\begin{cases} B_{rxn} L_{nx1} + w_{rx1} = 0 & \text{خطی} \\ f_{rx1}(L_{nx1}) = 0 & \text{غیر خطی} \end{cases}$$

برای مدل شرط مدل کلی  $f(\hat{L})=0$  را در نظر می‌گیریم. یکی از راه های حل مدل  $f(\hat{L})$  خطی کردن آن است.

$$f(\hat{L})=0 \rightarrow f(\hat{L}) = f(\hat{L}) \Big|_{\hat{L}=L} + \frac{\partial f}{\partial \hat{L}} \Big|_{\hat{L}=L} (\hat{L}-L) = 0 \quad ; \quad f(\hat{L}) \Big|_{\hat{L}=L} = w_{rx1} \quad , \quad \frac{\partial f}{\partial \hat{L}} \Big|_{\hat{L}=L} = B_{rxn}$$

$$\hat{L}-L = \hat{v}_{nx1} \Rightarrow w + B \hat{v}_{nx1} = 0 \rightarrow \boxed{r < n}$$

مشکله فوق یک دستگاه معادله ای است که جواب دارد هدف تعیین یک جواب از بین جوابات است.

$$\begin{cases} B \hat{v} + w = 0 \\ \hat{v}^T p \hat{v} \rightarrow \min \end{cases}$$

یکی از راه های حل معادله فوق استفاده از روش لاگرانژ است.

$$\Phi = \hat{v}^T p \hat{v} - 2 \lambda^T (B \hat{v} + w)$$

$$\begin{cases} \frac{\partial \Phi}{\partial \hat{v}} = 2 \hat{v}^T p - 2 \lambda^T B = 0 \\ \frac{\partial \Phi}{\partial \lambda} = -2 (B \hat{v} + w)^T = 0 \end{cases}$$

$$\begin{aligned} \text{①} \quad & P_{rxn} \hat{v}_{nx1} - B_{rxn}^T \lambda_{rx1} = 0 \rightarrow \text{مجهول } n \\ \text{②} \quad & B_{rxn} \hat{v}_{nx1} + w_{rx1} = 0 \rightarrow \text{معادله } r \end{aligned}$$

یکی از روش های حل جاگزینی مستقیم است

$$\text{①} \rightarrow \hat{v} = P^{-1} B^T \lambda \text{ ③}$$

$$\text{③} \rightarrow \text{②} \Rightarrow B P^{-1} B^T \lambda + w = 0 \rightarrow \lambda = -(B P^{-1} B^T)^{-1} w = -M^{-1} w \rightarrow \hat{v} = -P^{-1} B^T M^{-1} w$$

$$\hat{L} = L + \hat{v}$$

$$\Sigma_{\hat{v}\hat{v}} = \hat{J}_{\hat{v}w} \Sigma_{ww} \hat{J}_{\hat{v}w}^T = \bar{p}^{-1} B^T \bar{M}^{-1} \Sigma_{ww} \bar{M}^{-1} B \bar{p}^{-1} = \bar{p}^{-1} B^T \bar{M}^{-1} (\sigma^2 \underbrace{M^{-1}}_I) \bar{M}^{-1} B \bar{p}^{-1} =$$

$$\sigma^2 \bar{p}^{-1} B^T \bar{M}^{-1} B \bar{p}^{-1}$$

با توجه به اینکه ماتریس  $\bar{p}, d, \bar{p}, \bar{M}^{-1}$  هستند لذا داریم  $r(\Sigma_{\hat{v}\hat{v}}) = r(B) = 3$

و چون  $r < n$  لذا  $\Sigma_{\hat{v}\hat{v}}$  همواره singular است.

نکته:

\*  $\hat{v}$  و  $\hat{L}$  به دست آمده از مدل شرط با  $\hat{v}$  و  $\hat{L}$  به دست آمده از مدل پارامتریک و ترکیبی برابر خواهند بود.

\*  $\Sigma_{\hat{v}\hat{v}}$  و  $\Sigma_{\hat{L}\hat{L}}$  به دست آمده از مدل شرط با  $\Sigma_{\hat{v}\hat{v}}$  و  $\Sigma_{\hat{L}\hat{L}}$  به دست آمده از مدل پارامتریک و ترکیبی برابر خواهند بود.  
\* همواره در بین هیچ استثنایی به تعداد درجه آزادی می توانیم مدل شرط شکل دهیم.

$$df = d + c - \text{تعداد مجهولات} = \text{تعداد معادلات} = 3 \text{ (تعداد معادلات شرط)}$$


\* اگر مدل شرط حول معادلات خطی شد نیاز به بکوارانت خواهد بود.

$$\text{بکوارانت از مدل} \hat{L} = L_{\text{new}} \leftarrow w_{\text{new}} = f(L_{\text{new}}) \leftarrow 0 \leftarrow \text{نیاز به بکوارانت داریم}$$

$$\left. \begin{aligned} \hat{x} &= (A^T P A)^{-1} A^T P L \\ \delta \hat{x} &= (A^T P A)^{-1} A^T P \delta L \\ \delta \hat{x} &= (A^T \bar{M}^{-1} A)^{-1} A^T \bar{M}^{-1} w \end{aligned} \right\} \begin{aligned} r(A) &= u \\ \text{دارد رتبه} &= A \end{aligned}$$

$$\hat{v} = -\bar{p}^{-1} B^T (B \bar{p}^{-1} B^T)^{-1} w \rightarrow r(B) = 3 \rightarrow \text{دارد رتبه} = B$$

مثال:



$$H_A = 100 \text{ معلوم}$$

$$L_1 = 1^m$$

$$L_2 = 2^m$$

$$L_3 = 3.03$$

$$L_4 = 5$$

$$df = 4 - 3 + 0 + 0 = 1 \leftarrow$$

در مسئله ترانزیسیونی بود و هدف تعیین ارتفاع نقاط B, C, D است ( $p=1$ )  
مطلوبت معادلات سرنگین شده.

$$\hat{L}_1 + \hat{L}_2 + \hat{L}_3 = 0 \rightarrow w = f(\hat{L})|_{\hat{L}=L} = 1 + 2 - 3.03 = -0.03$$


$$B = \frac{\partial f}{\partial \hat{L}} = \begin{bmatrix} 1 & 1 & 1 & 0 \end{bmatrix}$$

$$\hat{v} = \frac{-0.03}{3} = -0.01 \rightarrow \hat{v} = \frac{-0.03}{3} \begin{bmatrix} 1 \\ 1 \\ 1 \\ 0 \end{bmatrix} = \begin{bmatrix} -0.01 & -0.01 & -0.01 & 0 \end{bmatrix}^T$$

$$\rightarrow \hat{L} = L + \hat{v} = \begin{bmatrix} 1.01 & 2.01 & 3.02 & 5 \end{bmatrix}$$

شکلی

مثال:



شکلی تر از باریک بود و به صورت رفت و برگشت و نظرات معلوم شد

ساختن شده و تحولات

روسی یا از ترک

برای تحولات

$$h_A = 100 \quad L_1 = 1m \quad L_2 = 2m \quad L_3 = 3.3m$$

$$\hat{L}_1 = \hat{h}_G - h_A$$

$$h_B = 106 \quad L_4 = -3.2 \quad L_5 = -2.1 \quad L_6 = -1$$

$$\hat{L}_2 = \hat{h}_F - \hat{h}_G$$

$$\rightarrow df = 6 - 2 = 4$$

$$\hat{L}_3 = h_B - \hat{h}_F$$

$\rightarrow$

$$\hat{L}_4 = \hat{h}_F - h_B$$

$$A = \begin{bmatrix} 1 & 0 \\ -1 & 1 \\ 0 & -1 \\ 0 & 1 \\ 1 & -1 \\ -1 & 0 \end{bmatrix}$$


$$\hat{L}_5 = \hat{h}_G - \hat{h}_F$$

$$\hat{L}_6 = h_A - \hat{h}_G$$

رنگ شرط:

$$\begin{cases} \hat{L}_1 + \hat{L}_6 = 0 \\ \hat{L}_2 + \hat{L}_5 = 0 \\ \hat{L}_3 + \hat{L}_4 = 0 \\ \hat{L}_1 + \hat{L}_2 + \hat{L}_3 - (h_B - h_A) = 0 \end{cases}$$

مثال: استاندارد مشخص شده اند



$$df = 12 - 4 - 8 + 4 + 0 = 4$$

$\downarrow \quad \downarrow \quad \downarrow \quad \downarrow \quad \downarrow$   
 استاندارد  $\Omega_0$   $d.d$   $c.d$

$$\triangle ABC: \alpha_1 + \dots + \alpha_4 - 180 = 0$$

$$\triangle BCD: \alpha_3 + \dots + \alpha_6 - 180 = 0$$

$$\triangle ADC: \alpha_5 + \dots + \alpha_8 - 180 = 0$$

$$\frac{\sin \alpha_1 \sin \alpha_3 \sin \alpha_5 \sin \alpha_7}{\sin \alpha_2 \sin \alpha_4 \sin \alpha_6 \sin \alpha_8} - 1 = 0$$

مدل با کمترین تابعی

$$\begin{cases} f(\hat{x}, \hat{L}) = 0 \\ g_{s,x}(\hat{x}) = 0 \end{cases} \quad \left. \begin{matrix} u \leq r \leq n \\ s \leq u \end{matrix} \right\} \text{ فرض کنید مدل اول بدون زیر مدل دوم و بطور مستقل قابل حل باشد (مثلاً انداز) } \quad \left. \begin{matrix} u \leq r \leq n \\ s \leq u \end{matrix} \right\}$$

میخواهم در مدل دوم را با هم سرشکن کنم. فرض کنید مدل اول بدون زیر مدل دوم و بطور مستقل قابل حل باشد (مثلاً انداز)  $g(x) = 0$  برای  $g$  defect نمی باشد.

با استفاده از خط سازی خواهم داشت

$$\begin{cases} A_{r \times u} \delta \hat{x}_{u \times 1} + B_{r \times n} \hat{v}_{n \times 1} + w_{r \times 1} = 0 & u \leq r \leq n, \quad r(A) = u, \quad r(B) = r \\ A_f \delta \hat{x}_{u \times 1} + w_f = 0 & s \leq u, \quad r(A_f) = s \end{cases}$$

معادلات فوق به مدل با کمترین تغییرات (functional constraint) محدودند

امکان سرشکنی مدل:  $u \leq r + s \leq n + u$

$$\begin{cases} A \delta \hat{x} + B \hat{v} + w = 0 \\ A_f \delta \hat{x} + w_f = 0 \end{cases} \rightarrow \begin{pmatrix} A \\ A_f \end{pmatrix}_{(r+s) \times u} \delta \hat{x} + \begin{pmatrix} B \\ 0 \end{pmatrix}_{(r+s) \times n} \hat{v} + \begin{pmatrix} w \\ w_f \end{pmatrix}_{(r+s) \times 1} = 0 \rightarrow A^* \delta \hat{x} + B^* \hat{v} + w^* = 0$$

مثال بادر:  $r(B^*) = r + s$ ,  $r(A^*) = u$  باشد تا بتوان از مدل فوق به عنوان مدل ترکیبی استفاده کرد.

$$r(A^*) = u \quad \checkmark$$

$$r(B^*) = r \neq r + s \quad \times$$

میل برای حل از روش لاگرانژ تعمیم یافته استفاده می کنیم.

$$\phi = \hat{v}^T p \hat{v} - 2 \lambda^T (A \delta \hat{x} + B \hat{v} + w) - 2 \lambda_f^T (A_f \delta \hat{x} + w_f) \rightarrow \min$$

$$\frac{\partial \phi}{\partial \hat{v}} = 2 \hat{v}^T p - 2 \lambda^T B = 0$$

$$\textcircled{1} \quad p \hat{v} - B^T \lambda = 0$$

$$\frac{\partial \phi}{\partial \delta \hat{x}} = -2 \lambda^T A - 2 \lambda_f^T A_f = 0$$

برای به دست آوردن  
از شرط

$$\textcircled{2} \quad A^T \lambda + A_f^T \lambda_f = 0$$

$$\frac{\partial \phi}{\partial \lambda} = -2 (A \delta \hat{x} + B \hat{v} + w)^T = 0$$

$$\textcircled{3} \quad A \delta \hat{x} + B \hat{v} + w = 0$$

$$\frac{\partial \phi}{\partial \lambda_f} = -2 (A_f \delta \hat{x} + w_f)^T = 0$$

$$\textcircled{4} \quad A_f \delta \hat{x} + w_f = 0$$

یعنی از روشی حل جایگزینی تعمیم یافته:

$$\textcircled{1} \rightarrow \hat{v} = p^{-1} B^T \lambda \quad \textcircled{5}$$

$$\textcircled{5} \rightarrow \textcircled{3} \Rightarrow A \delta \hat{x} + B p^{-1} B^T \lambda + w = 0 \rightarrow \lambda = - (B p^{-1} B^T)^{-1} (A \delta \hat{x} + w) \quad \textcircled{6}$$

$$\textcircled{6} \rightarrow \textcircled{2} \Rightarrow -A^T (B p^{-1} B^T)^{-1} (A \delta \hat{x} + w) + A_f^T \lambda_f = 0 \rightarrow \delta \hat{x} = (A^T M^{-1} A)^{-1} (A_f^T \lambda_f - A^T M^{-1} w) = (A^T M^{-1} A)^{-1} A_f^T \lambda_f - (A^T M^{-1} A)^{-1} A^T M^{-1} w \quad \textcircled{7}$$

$$\textcircled{7} \rightarrow \textcircled{4} \Rightarrow A_f (A^T M^{-1} A)^{-1} A_f^T \lambda_f - A_f (A^T M^{-1} A)^{-1} A^T M^{-1} w + w_f = 0 \rightarrow \lambda_f = (A_f (A^T M^{-1} A)^{-1} A_f^T)^{-1} (A_f (A^T M^{-1} A)^{-1} A^T M^{-1} w - w_f) \quad \textcircled{8}$$

$$\textcircled{8} \rightarrow \textcircled{7} \Rightarrow \delta \hat{x}_{12} = (A^T M^{-1} A)^{-1} A_f^T [\textcircled{8}] - (A^T M^{-1} A)^{-1} A^T M^{-1} w$$

$$\delta \hat{x}_{12} = \delta \hat{x}_1 + \Delta_1 \rightarrow \Delta_1 = (A^T M^{-1} A)^{-1} A_f^T \lambda_f \quad \sum \delta \hat{x}_{12} = \sum \delta \hat{x}_1 + \Delta_2 \quad \Delta_2 = ?$$



روش انتر کاسترین (Inner constraint): سه شگنی کاسترین داخلی

اگر به دلیل وجود d.defect (فرض کنید c.defect نداریم) یا به عبارت دیگر به دلیل عدم وجود سیستم محففات توانیم محمولات را برآورد کنیم، متوانیم با غریب سیستم محففات محمولات را برآورد کنیم. (d.d. را بگیریم)

یکی از روش های تقیین سیستم محففات در فرض d.d روش کاسترین داخلی داخلی می باشد. در این روش در حقیقت معادلات شدگی به صورت  $E\delta\hat{x}=0$  به دسته معادلات  $A\delta\hat{x}+B\hat{v}+w=0$  ( $\delta\hat{L}=A\delta\hat{x}$ ) اضافه می کنیم تا بتوانیم محمولات را برآورد کنیم. ماتریس E این خاصیت را دارد که کمبود مرتبه ماتریس A را جبران می کند. لازم به ذکر است روش I.C حالت خاصی از روش M.C می باشد. زیرا به تعداد حداقل مورد نیاز، معادلات کاسترینیت برای تقیین سیستم محففات به معادلات  $A\delta\hat{x}+B\hat{v}+w=0$  اضافه می کنیم. (معادلات کاسترینیت رابطی بین محمولات است)

$$\begin{cases} A\delta\hat{x}+B\hat{v}+w=0 \\ E\delta\hat{x}=0 \end{cases} \quad \begin{pmatrix} A \\ E \end{pmatrix} \delta\hat{x} + \begin{pmatrix} B \\ 0 \end{pmatrix} \hat{v} + \begin{pmatrix} w \\ 0 \end{pmatrix} = 0$$

$$A^* \delta\hat{x} + B^* \hat{v} + w^* = 0$$

$$r(A^*) = r\left(\begin{pmatrix} A \\ E \end{pmatrix}\right) = r(A) + r(E) = u$$

اگر از روش I.C محاسبه شود دارای خاصیت  $AE^T=0$  است.

فرض کنید شبکه ای p نقطه ای در سطحی داریم که محففات آنها مجهول است.

1) اگر شبکه ای مشعل انتقال درجهت x داشته باشد (defect درجهت x) برای فرض آن درجهت انتقال درجهت x برای سیستم محففات فرض کنیم محففات x مرکز ثقل شبکه (نقطه ای فرضی داخل شبکه) به دور سه شگنی و قبل از آن ثابت باشد

$$1) \hat{x}_G = x_{G_0} \Rightarrow \frac{1}{p} \sum_{i=1}^p \hat{x}_i = \frac{1}{p} \sum_{i=1}^p x_{0i}$$

محففات قبل از سه شگنی      له محففات نقطه بعد از سه شگنی

$$\rightarrow \frac{1}{p} \sum_{i=1}^p (\hat{x}_i - x_{0i}) = 0 \rightarrow \sum_{i=1}^p \delta\hat{x}_i = 0$$

2) اگر شبکه ای مشعل انتقال y داشته باشد (defect درجهت y) برای فرض آن درجهت انتقال درجهت y برای سیستم محففات فرض کنیم y مرکز ثقل شبکه (نقطه ای فرضی در داخل شبکه) به دور سه شگنی و قبل از آن ثابت است.

$$2) \hat{y}_G = y_{G_0} \rightarrow \frac{1}{p} \sum_{i=1}^p \hat{y}_i = \frac{1}{p} \sum_{i=1}^p y_{0i}$$

$$\rightarrow \frac{1}{p} \sum_{i=1}^p (\hat{y}_i - y_{0i}) = 0 \rightarrow \sum_{i=1}^p \delta\hat{y}_i = 0$$

3) اگر شبکه مثل دوران داشته باشد یعنی دورانی یا ترجمه سیستم مختصات حرکت نشده باشد و defect دوران داشته باشیم، برای حل فرض می‌کنیم میانگین مرکز ثقل شبکه به نقطه شبکه بعد از سرنگی و قبل از سرنگی ثابت باشد.

$$3) \hat{\alpha}_{Gi} = \bar{\alpha}_{Gi0} \rightarrow \frac{1}{P} \sum_{i=1}^P \hat{\alpha}_{Gi} = \frac{1}{P} \sum_{i=1}^P \alpha_{Gi0} \Rightarrow \sum_{i=1}^P \delta \hat{\alpha}_{Gi} = 0$$

$$\hat{\alpha}_{Gi} = \tan^{-1} \frac{\hat{x}_i - \hat{x}_{G0}}{\hat{y}_i - \hat{y}_{G0}} \pm K\pi = \tan^{-1} \frac{\hat{x}_i - x_{G0}}{\hat{y}_i - y_{G0}} \pm K\pi$$

$$\rightarrow \delta \hat{\alpha}_{Gi} = \left. \frac{\partial \hat{\alpha}_{Gi}}{\partial \hat{x}_i} \right|_{\hat{x}=\alpha_{0i}} (\hat{x} - \alpha_{0i}) + \left. \frac{\partial \hat{\alpha}_{Gi}}{\partial \hat{y}_i} \right|_{\hat{y}=y_{0i}} (\hat{y}_i - y_{0i}) \Rightarrow$$

$$\frac{\partial \hat{\alpha}_{Gi}}{\partial \hat{x}_i} = \frac{\hat{y}_i - y_{G0}}{(\hat{x}_i - x_{G0})^2 + (\hat{y}_i - y_{G0})^2} = \frac{\hat{y}_{0i} - y_{G0}}{(L_{Gi0})^2}$$

$$\frac{\partial \hat{\alpha}_{Gi}}{\partial \hat{y}_i} = \frac{-(\hat{x}_{0i} - x_{G0})}{(L_{Gi0})^2}$$

$$\Rightarrow \sum_{i=1}^P \frac{(y_{0i} - y_{G0})}{(L_{Gi0})^2} \delta \hat{x}_i + \frac{-(x_{0i} - x_{G0})}{(L_{Gi0})^2} \delta \hat{y}_i = 0 \rightarrow (L_{Gi0} = L_{Gj0} = L_0) \quad \text{فرض می‌کنیم وی شبکه ای دایره ای است}$$

یعنی فرض می‌کنیم همه طول‌ها وی هستند (فاصله نقاط مرکز ثقل برابر است)

$$\sum (y_{0i} - y_{G0}) \delta \hat{x}_i - (x_{0i} - x_{G0}) \delta \hat{y}_i = 0$$

$$\rightarrow \sum (y_{0i} \delta \hat{x}_i - x_{0i} \delta \hat{y}_i) - \sum y_{G0} \delta \hat{x}_i + \sum x_{G0} \delta \hat{y}_i = 0 \rightarrow \sum_{i=1}^P y_{0i} \delta \hat{x}_i - x_{0i} \delta \hat{y}_i = 0$$

4) اگر شبکه مثل مقیاس داشته باشد (مقیاس حرکت نشده باشد) برای حل این مشکل فرض می‌کنیم میانگین طول مرکز ثقل شبکه به نقطه قبل و بعد از سرنگی ثابت باشد.

ثابت در برابر باشد

$$4) \hat{L}_{Gi} = \bar{L}_{Gi0} \rightarrow \frac{1}{P} \sum_{i=1}^P \hat{L}_{Gi} = \frac{1}{P} \sum_{i=1}^P L_{Gi0} \rightarrow \sum_{i=1}^P \delta \hat{L}_{Gi} = 0$$

$$\rightarrow \sum x_{i0} \delta \hat{x}_i + y_{i0} \delta \hat{y}_i = 0$$

$$\begin{cases} \delta L_{n \times 1} = A_{n \times u} \delta \hat{x}_{u \times 1} \rightarrow r(A) = u - d \quad (u = p) \\ E_{d \times u} \delta \hat{x}_{u \times 1} = 0 \end{cases}$$

$$E \delta \hat{x} = \begin{bmatrix} 1 & 0 & 1 & 0 & \dots & 1 & 0 \\ 0 & 1 & 0 & 1 & \dots & 0 & 1 \\ y_{01} - x_{01} & y_{02} - x_{02} & \dots & y_{0p} - x_{0p} \\ x_{01} & y_{01} & x_{02} & y_{02} & \dots & x_{0p} & y_{0p} \end{bmatrix} \begin{bmatrix} \delta x_1 \\ \delta y_1 \\ \vdots \\ \delta x_p \\ \delta y_p \end{bmatrix} \rightarrow \delta \hat{x} = (A^T P A + E^T E)^{-1} A^T P \delta L$$

$$= (A^T P A)^+ A^T P \delta L$$

$$\Sigma_{\delta \hat{x}} = \delta_0^2 (A^T P A)^+ = \delta_0^2 (A^T P A + E^T E)^{-1} A^T P A (A^T P A + E^T E)^{-1}$$

سه شگنی

شکله ارتعاشی با نقطه بار ارتعاش مجهول:

$$\hat{H}_G = \hat{H}_{G0} \rightarrow \frac{1}{P} \sum_{i=1}^P \hat{H}_i = \frac{1}{P} \sum_{i=1}^P H_{i0} \rightarrow \sum_{i=1}^P \delta H_i = 0$$

$$\rightarrow E \delta \hat{x} = \begin{bmatrix} 1 & 1 & 1 & \dots & 1 \end{bmatrix} \begin{bmatrix} \delta H_1 \\ \delta H_2 \\ \vdots \end{bmatrix} = 0$$

شکله کاسترین داخلی همیشه به روش غیر خطی حل می شود چون نیاز به بهداری اولیه داریم.

مربای Inner constraint:

$$1) \text{ Norm: } \|\delta \hat{x}\|_2^2 = \delta \hat{x}^T \delta \hat{x} \rightarrow \min$$

$$2) \text{ tr}(\sum \delta \hat{x}) \rightarrow \min$$

معیار:

1- جواب حاصل از این روش شدیداً تحت تأثیر خطاهاست.

2- هیچ توصیه فیزیکی برای ثابت نگه داشتن مرکز ثقل شکله نداریم.

ماتریس E در حالت سه بعدی

$$E = \begin{bmatrix} 1 & 0 & 0 & 1 & 0 & 0 & \dots \\ 0 & 1 & 0 & 0 & 1 & 0 & \dots \\ 0 & 0 & 1 & 0 & 0 & 1 & \dots \\ 0 & z_{01} & -y_{01} & 0 & z_{02} & -y_{02} & \dots \\ z_{01} & 0 & -x_{01} & z_{02} & 0 & -x_{02} & \dots \\ x_{01} & y_{01} & z_{01} & x_{02} & y_{02} & z_{02} & \dots \end{bmatrix}$$

پردازش داده ها به روش سه شگنی:

در پردازش داده های قبل از سرشگنی نمونه های قابل مستند از یک جامعه باشند (آماره). در پردازش داده های بعد از سرشگنی کنترل نتایج از نظر قابل قبول بودن می باشد. در ضمن این پردازش می توانیم سازگاری مشاهدات مختلف از یک جامعه باشند را با هم تست کنیم. هرگونه تصمیم گیری در مورد قابل قبول بودن نتایج باید با کمتری آزمونهای آماره انجام گیرد. یکی از این آزمونهای آماره، آزمون فاکتور واریانس نامیده می شود. اگر هیچ مشکلی در سرشگنی وجود نداشته باشد، انتظار می رود  $\hat{\delta}_0^2 = \delta_0^2$  باشد. بنابراین می توانیم آزمون آماره به شکل زیر برگزینیم:

$$\begin{cases} H_0: \hat{\delta}_0^2 = \delta_0^2 \rightarrow \frac{\hat{\delta}_0^2}{\delta_0^2} = 1 & \text{قابل قبول} \\ H_1: \hat{\delta}_0^2 \neq \delta_0^2 \rightarrow \frac{\hat{\delta}_0^2}{\delta_0^2} \neq 1 & \text{غیر قابل قبول} \end{cases}$$

برای رد یا قبول  $H_0$  و یا قبول ریسک  $\alpha$  برای خطای نوع اول می توانیم حاصله بحرانی زیر را در نظر بگیریم:

$$\hat{\sigma}_o^2 = \frac{\hat{v}^T P \hat{v}}{df} = \frac{\sigma_o^2 \hat{v}^T \Sigma_L^{-1} \hat{v}}{df} \Rightarrow \frac{df \hat{\sigma}_o^2}{\sigma_o^2} = \hat{v}^T \Sigma_L^{-1} \hat{v} \rightarrow \chi_{df}^2$$

$$\rightarrow \chi_{df, \frac{\alpha}{2}}^2 < \frac{df \hat{\sigma}_o^2}{\sigma_o^2} < \chi_{df, 1-\frac{\alpha}{2}}^2 \rightarrow H_0 \text{ فرض قبول}$$

else  $\rightarrow H_0$  قابل قبول  $\rightarrow H_1$  غیر قابل قبول

دلیل رد فرض  $H_0$ :

\* (1) نرمال بودن  $\hat{v}_i$  یا  $w_i$  می باشد.

$$\hat{v}_i \rightarrow N(0, \sigma_{\hat{v}_i}^2) \quad \text{یا} \quad w_i = - \frac{\hat{v}_i}{\sigma_{\hat{v}_i}} \rightarrow N(0, 1)$$

$$\Sigma_{\hat{v}\hat{v}} \rightarrow \sigma_{\hat{v}_i}^2$$

\* (2) اشتباه بودن مشاهدات که منظر اشتباه بودن  $\hat{v}_i$  می باشد

$$\text{معمولاً: } \frac{df \hat{\sigma}_o^2}{\sigma_o^2} > \chi_{df, 1-\frac{\alpha}{2}}^2$$

(3) وجود اشتباهات سیستمی

\* \* (4) عدم صیغ بودن ماتریس وزن (عدم تناسب صیغ بین وزنها مشاهدات)

(5) خطای خطی کردن دیتا اولیه (بایگ رار ط می شود)

\* (6) وجود خطای S.Y.S (مدل ریاضی نادرست)

(7) ضعف هندسی شبکه (مثلاً درجه آزادی بالا باشد)

روش کشف مشاهدات اشتباه:

$$w_i = \frac{\hat{v}_i}{\sigma_{\hat{v}_i}} \rightarrow N(0, 1)$$



روش اول: الف) حد اورد  $\hat{v}_i$  و  $E(\hat{v}_i) = 0$

ب)  $\sigma_{\hat{v}_i}$  برآورد باشد و  $E(\hat{v}_i) = 0$

ج)  $\sigma_{\hat{v}_i}$  برآورد باشد و  $E(\hat{v}_i) = 0$

$$\text{الف) } z_{\frac{\alpha}{2}} < w_i < z_{1-\frac{\alpha}{2}}$$

$$\text{ب) } t_{df, \frac{\alpha}{2}} < w_i < t_{df, 1-\frac{\alpha}{2}}$$

$$\text{ج) } \tau_{df, \frac{\alpha}{2}} < w_i < \tau_{df, 1-\frac{\alpha}{2}}$$

\* در این روش به دلیل اینکه از  $L_2$  استفاده می کنیم و خط به صورت global ن می تواند باشد

است مشاهدات اشتباه بوده می بدلیل دیگر اشتباهات در آزمون رد شود.




این روند آفقد رادامی باید تا آزمون قبول شود.

مشاهده ای را که در مرحله اول حذف شده بوده به نسبت اخذ کرده سرسنگی میکنم. اگر درست فاکتور دار یا س نامزد قبول شد، مش مشاهده اشتباه نبوده است و اگر در مش مشاهده اشتباه نبوده است. برای بقیه نیز همین کار را انجام داده و مش هوای را که اشتباه حذف شده اند به نسبت برمی گردانیم.

\* حذف مش مشاهده ممکن است باعث ضعف ضدی شبکه شود. دلیلی برای رد آزمون فاکتور دار نیست.

با استفاده از متد کمترین مربعات، مقادیر استیاه  $u$  را با توجه به شکل داده شده و مقادیرهای انجام شده برست آورید.



$$\begin{aligned}\theta_1 &= 50^\circ 06' 50'' \\ \theta_2 &= 101^\circ 30' 47'' \\ \theta_3 &= 98^\circ 41' 17'' \\ \theta_4 &= 59^\circ 17' 01''\end{aligned}$$

$$x_R = 865.40$$

$$x_S = 2432.55$$

$$x_T = 2865.22$$

$$y_R = 4527.15$$

$$y_S = 2047.25$$

$$y_T = 27.15$$

① محاسبه مقدار تقریبی برای  $u$

$$① RS = \sqrt{(2432.55 - 865.40)^2 + (4527.15 - 2047.25)^2} = 2933.58$$

$$② AZ_{RS} = 147^\circ 42' 34'' \Rightarrow AZ_{RU_0} = 147^\circ 42' 34'' - 50^\circ 06' 50'' = 97^\circ 35' 44''$$

$$③ RU_0 = \frac{RS \sin(\theta_2)}{\sin(180 - \theta_1 - \theta_2)} = 6049.00$$

$$④ x_{u_0} = x_R + RU_0 \sin(AZ_{RU_0}) = 6861.35$$

$$y_{u_0} = y_R + RU_0 \cos(AZ_{RU_0}) = 3727.59$$

$$⑤ SU_0 = \sqrt{(x_{u_0} - x_S)^2 + (y_{u_0} - y_S)^2} = 4736.83$$

$$TU_0 = \sqrt{(x_{u_0} - x_T)^2 + (y_{u_0} - y_T)^2} = 5446.29$$

② فرمول بندی برای انجام سرنگش و حفظ کردن فرمول، در اینجا شرط کنترل  $\chi^2$  فرقی نسبیست لذا  $dn$  و  $dy$  مربوط به آن ها مفروضه کرد.

لذا ملاحظات که 4 زاویه افق هستند بصورت زیر فرمول بندی می شوند

$$\frac{y_R - y_{u_0}}{(RU_0)^2} dn_{u_0} + \frac{x_{u_0} - x_R}{(RU_0)^2} dy_{u_0} = \theta_1 - \left\{ \tan^{-1} \left( \frac{x_S - x_R}{y_S - y_R} \right) - \tan^{-1} \left( \frac{x_{u_0} - x_R}{y_{u_0} - y_R} \right) + 0 \right\} + \gamma_1$$

$$\frac{y_{u_0} - y_S}{(SU_0)^2} dn_{u_0} + \frac{x_S - x_{u_0}}{(SU_0)^2} dy_{u_0} = \theta_2 - \left\{ \tan^{-1} \left( \frac{x_{u_0} - x_S}{y_{u_0} - y_S} \right) - \tan^{-1} \left( \frac{x_R - x_S}{y_R - y_S} \right) + 0 \right\} + \gamma_2$$

$$\frac{y_S - y_{u_0}}{(SU_0)^2} dn_{u_0} + \frac{x_{u_0} - x_S}{(SU_0)^2} dy_{u_0} = \theta_3 - \left\{ \tan^{-1} \left( \frac{x_T - x_S}{y_T - y_S} \right) - \tan^{-1} \left( \frac{x_{u_0} - x_S}{y_{u_0} - y_S} \right) + 180 \right\} + \gamma_3$$

$$\frac{y_{u_0} - y_T}{(TU_0)^2} dn_{u_0} + \frac{x_T - x_{u_0}}{(TU_0)^2} dy_{u_0} = \theta_4 - \left\{ \tan^{-1} \left( \frac{x_{u_0} - x_T}{y_{u_0} - y_T} \right) - \tan^{-1} \left( \frac{x_S - x_T}{y_S - y_T} \right) + 0 \right\} + \gamma_4$$

$\ddot{J} = \begin{bmatrix} 4527.15 - 3727.59 \\ (6049.00)^2 \\ 3727.59 - 2047.25 \\ (4736.83)^2 \\ 2047.25 - 3727.59 \\ (4736.83)^2 \\ 3727.59 - 27.15 \\ (5446.29)^2 \end{bmatrix} \begin{bmatrix} 6861.35 - 865.40 \\ (6049.00)^2 \\ 2432.55 - 6861.35 \\ (4736.83)^2 \\ 6861.35 - 2432.55 \\ (4736.83)^2 \\ 2865.22 - 6861.35 \\ (5446.29)^2 \end{bmatrix} = \begin{bmatrix} 4.507 & 33.800 \\ 15.447 & -40.713 \\ -15.447 & 40.713 \\ 25.732 & -27.788 \end{bmatrix}$

ست و بیست و دو

$K = \begin{bmatrix} 50 & 06 & 50 - \left\{ 09^{-1} \left( \frac{2432.55 - 865.40}{2047.25 - 4527.15} \right) - 09^{-1} \left( \frac{6861.35 - 865.40}{3727.59 - 4527.15} \right) + 0 \right\} \\ 101 & 30 & 47 - \left\{ \right\} \\ 98 & 41 & 17 - \left\{ \right\} \\ 59 & 17 & 01 - \left\{ \right\} \end{bmatrix}$

ست و بیست و سه

$= \begin{bmatrix} 0.00 \\ 0.00 \\ -0.69 \\ -20.23 \end{bmatrix}$

$\ddot{J}^T \ddot{J} = \begin{bmatrix} 1159.7 & -1820.5 \\ -1820.5 & 5229.7 \end{bmatrix} \quad Q_{nn} = (\ddot{J}^T \ddot{J})^{-1} = \begin{bmatrix} 0.001901 & 0.000662 \\ 0.000662 & 0.000422 \end{bmatrix}$

$\ddot{J}^T K = \begin{bmatrix} -509.9 \\ 534.1 \end{bmatrix} \quad X = [\ddot{J}^T \ddot{J}]^{-1} [\ddot{J}^T K] = \begin{bmatrix} 0.001901 & 0.000662 \\ 0.000662 & 0.000422 \end{bmatrix} \begin{bmatrix} -509.9 \\ 534.1 \end{bmatrix}$

$= \begin{bmatrix} dx_u \\ dy_u \end{bmatrix}$

$dx_u = -0.62$

$x_u = x_0 + dx_u = 6860.73$

$dy_u = -0.11$

$y_u = y_0 + dy_u = 3727.48$

$\hat{V} = \ddot{J}X - K = \begin{bmatrix} 4.507 & 33.800 \\ 15.447 & -40.713 \\ -15.447 & 40.713 \\ 25.732 & -27.788 \end{bmatrix} \begin{bmatrix} -0.62 \\ -0.11 \end{bmatrix} - \begin{bmatrix} 0.00 \\ 0.00 \\ -0.69 \\ -20.23 \end{bmatrix} = \begin{bmatrix} -6.5 \\ -5.1 \\ 5.8 \\ 7.3 \end{bmatrix}$

$\hat{V}^T \hat{V} = \begin{bmatrix} -6.5 & -5.1 & 5.8 & 7.3 \end{bmatrix} \begin{bmatrix} -6.5 \\ -5.1 \\ 5.8 \\ 7.3 \end{bmatrix} = [155.2]^2$

$\hat{S}_0^2$

$\hat{S}_0 = \sqrt{\frac{\hat{V}^T \hat{V}}{m-n}} = \sqrt{\frac{155.2}{4-2}} = \pm 8.8^{\sim}$

محاسبه خطای تخمیناتی برای پارامترها

$\hat{S}_{x_u} = \hat{S}_0 \sqrt{Q_{x_u x_u}} = \pm 8.8 \sqrt{0.001901} = \pm 0.38^{\sim}$

$\hat{S}_{y_u} = \hat{S}_0 \sqrt{Q_{y_u y_u}} = \pm 8.8 \sqrt{0.000442} = \pm 0.18^{\sim}$

$\hat{S}_u = \sqrt{\hat{S}_{x_u}^2 + \hat{S}_{y_u}^2} = \pm 0.42^{\sim}$



where  $\sum wv^2$  in matrix form is  $V^T W V$ .

Since these standard deviations of unit weight relate to the overall adjustment and not a single quantity, they are referred to as *reference standard deviations*. Computation of the reference standard deviations for both unweighted and weighted examples are illustrated below.

### 11.5.1 Unweighted Example

In the example of Section 11.3, there were 7 - 3 or 4 degrees of freedom. Using the residuals given in Equation (11.7), the system's reference standard deviation is determined using the algebraic expression of Equation (11.14) as:

$$S_0 =$$

$$= \sqrt{\frac{(0.041)^2 + (0.019)^2 + (-0.062)^2 + (-0.058)^2 + (0.022)^2 + (-0.017)^2 + (0.005)^2}{7 - 3}} = \pm 0.05 \text{ ft} \quad (11.16)$$

This can be computed using the matrix expression of Equation (11.14) as

$$S_0 = \sqrt{\frac{V^T V}{r}}$$

$$V^T V = [0.041 \quad 0.019 \quad -0.062 \quad -0.058 \quad 0.022 \quad -0.017 \quad 0.005]$$

$$\times \begin{bmatrix} 0.041 \\ 0.019 \\ -0.062 \\ -0.058 \\ 0.022 \\ -0.017 \\ 0.005 \end{bmatrix} = 0.10$$

$$S_0 = \sqrt{\frac{0.10}{4}} = \pm 0.05 \text{ ft} \quad (11.17)$$

### 11.5.2 Weighted Example

Notice that the weights are used when computing the reference standard deviation in Equation (11.15). That is, each residual is squared and multiplied

by its weight, and thus the reference standard deviation, computed using no matrix methods, is

$$S_0 = \sqrt{\frac{3(0.050)^2 + 4(0.010)^2 + 6(-0.053)^2 + 4(-0.067)^2 + 6(0.019)^2 + 6(-0.011)^2 + 6(0.010)^2}{7 - 3}} = \sqrt{\frac{0.04598}{4}} = \pm 0.107 \quad (11.11)$$

It is left as an exercise to verify this result by solving the matrix expression of Equation (11.15).

### 11.6 ANOTHER WEIGHTED ADJUSTMENT

**Example 11.1** The level net shown in Figure 11.3 was measured with the following results (the elevation differences and standard deviations are given in meters, and the elevation of A is 437.596 m):

From:	To:	AElev	$\sigma$	From:	To:	AElev	$\sigma$
A	B	10.509	0.006	D	A	-7.348	0.003
B	C	5.360	0.004	B	D	-3.167	0.004
C	D	-8.523	0.005	A	C	15.881	0.012

What are the most probable values for the elevations of B, C, and D?

#### SOLUTION

**Step 1:** Write the observation equations without their weights:

- (1)  $+B = A + 10.509 + v_1 = 448.105 + v_1$
- (2)  $-B + C = 5.360 + v_2$
- (3)  $-C + D = -8.523 + v_3$
- (4)  $-D = -A - 7.348 + v_4 = -444.944 + v_4$
- (5)  $-B + D = -3.167 + v_5$
- (6)  $+C = A + 15.881 + v_6 = 453.477 + v_6$

**Step 2:** Rewrite observation equations in matrix form  $AX = L + V$  as:






Figure 11.3 Level net.

$$\begin{bmatrix} 1 & 0 & 0 \\ -1 & 1 & 0 \\ 0 & -1 & 1 \\ 0 & 0 & -1 \\ -1 & 0 & 1 \\ 0 & 1 & 0 \end{bmatrix} \begin{bmatrix} B \\ C \\ D \end{bmatrix} = \begin{bmatrix} 448.105 \\ 5.360 \\ -8.523 \\ -444.944 \\ -3.167 \\ 453.477 \end{bmatrix} + \begin{bmatrix} v_1 \\ v_2 \\ v_3 \\ v_4 \\ v_5 \\ v_6 \end{bmatrix} \quad (11.19)$$

Step 3: In accordance with Equations (9.4) and (9.6), form the weight matrix as

$$W = \begin{bmatrix} \frac{1}{0.006^2} & 0 & 0 & 0 & 0 & 0 \\ 0 & \frac{1}{0.004^2} & 0 & 0 & 0 & 0 \\ 0 & 0 & \frac{1}{0.005^2} & 0 & 0 & 0 \\ 0 & 0 & 0 & \frac{1}{0.003^2} & 0 & 0 \\ 0 & 0 & 0 & 0 & \frac{1}{0.004^2} & 0 \\ 0 & 0 & 0 & 0 & 0 & \frac{1}{0.012^2} \end{bmatrix} \quad (11.20)$$

from which

$$W = \begin{bmatrix} 27,778 & 0 & 0 & 0 & 0 & 0 \\ 0 & 62,500 & 0 & 0 & 0 & 0 \\ 0 & 0 & 40,000 & 0 & 0 & 0 \\ 0 & 0 & 0 & 111,111 & 0 & 0 \\ 0 & 0 & 0 & 0 & 62,500 & 0 \\ 0 & 0 & 0 & 0 & 0 & 6944 \end{bmatrix} \quad (11.21)$$

Step 4: Compute the normal equations using Equation (10.34):

$$(A^T W A) X = N X = A^T W L \quad (11.22)$$

This gives

$$N = \begin{bmatrix} 152,778 & -62,500 & -62,500 \\ -62,500 & 109,444 & -40,000 \\ -62,500 & -40,000 & 213,611 \end{bmatrix} \quad X = \begin{bmatrix} B \\ C \\ D \end{bmatrix}$$

$$A^T W L = \begin{bmatrix} 12,310,298.611 \\ 3,825,065.833 \\ 48,899,364.722 \end{bmatrix}$$

Step 5: Solve for the  $X$  matrix using Equation (10.35), which yields

$$X = \begin{bmatrix} 448.1087 \\ 453.4685 \\ 444.9436 \end{bmatrix} \quad (11.23)$$

Step 6: Compute the residuals using the matrix expression  $V = AX - L$ .

$$V = \begin{bmatrix} 448.1087 \\ 5.3598 \\ -8.5249 \\ -444.9436 \\ -3.1651 \\ 453.4685 \end{bmatrix} - \begin{bmatrix} 448.105 \\ 5.360 \\ -8.523 \\ -444.944 \\ -3.167 \\ 453.477 \end{bmatrix} = \begin{bmatrix} 0.0037 \\ -0.0002 \\ -0.0019 \\ 0.0004 \\ 0.0019 \\ -0.0085 \end{bmatrix} \quad (11.24)$$

Step 7: Calculate the reference standard deviation for the adjustment using the matrix expression of Equation (11.15).

$$\begin{aligned} V^T W V &= [0.0037 \quad -0.0002 \quad -0.0019 \quad 0.0004 \quad 0.0019 \quad -0.0085] W \\ &\quad \times \begin{bmatrix} 0.0037 \\ -0.0002 \\ -0.0019 \\ 0.0004 \\ 0.0019 \\ -0.0085 \end{bmatrix} = [1.26976] \end{aligned} \quad (11.25)$$

Since the number of system redundancies is the number of observations minus the number of unknowns,  $r = 6 - 3 = 3$ , and thus  $S_0$  is

$$S_0 = \sqrt{\frac{1.26976}{3}} = \pm 0.6575 \text{ m} \quad (11.26)$$

Step 8: Tabulate the results showing the adjusted elevation differences, their residuals, and the final adjusted elevations.

From	To	Adjusted ΔElev	Residual	Station	Adjusted Elevation
A	B	10.513	0.004	A	437.596
B	C	5.360	0.000	B	448.109
C	D	-8.525	-0.002	C	453.468
D	A	-7.348	0.000	D	444.944
B	D	-3.165	0.002		
A	C	15.872	-0.009		

## PROBLEMS

Note: For problems below requiring least-squares adjustment, if a computer program is not distinctly specified for use in the problem, it is expected that the least-squares algorithm will be solved using the program MATRIX which is included within the diskette supplied with the book.

11.1 For the leveling network shown in Figure 11.4, calculate the most probable elevations for X and Y. Use an unweighted least-squares adjustment with the observed values given in the accompanying table.

Line	ΔElev
1	+1.00
2	+0.08
3	+0.92
4	-1.00
5	+0.08




Figure 11.4

11.2 For Problem 11.1, compute the reference standard deviation and tabulate the adjusted observations and their residuals.

11.3 Do Problem 11.1 using Program ADJUST.

11.4 For the leveling network shown in Figure 11.5, calculate the most probable elevations for X, Y, and Z. The observed values and line lengths are given in the table. Apply appropriate weights in the computations.

Line	Length	ΔElev	Line	Length	ΔElev
1	4	+1.05	4	2	-1.95
2	4	-0.95	5	1	+0.10
3	2	+2.10	6	3	+0.05

11.5 For Problem 11.4, compute the reference standard deviation, and tabulate the adjusted observations and their residuals.

11.6 Use Program ADJUST to solve Problem 11.4.

11.7 A line of differential levels was run from benchmark Oak (elevation 753.01) to station 13+00 on a proposed road alignment. It continued along the alignment to 19+00. Rod readings were taken on stakes set at each full station. The circuit then closed on benchmark Bridge having an elevation of 764.95 ft. The observed elevation differences, in order, are -3.03, 4.10, 4.03, 7.92, 7.99, -6.00, -6.02, and 2.98 ft. A check measurement between benchmark Rock (elevation = 772.39 ft) and station 16+00 gives an elevation difference of -6.34 ft.

- What are the most probable values for the adjusted elevation differences?
- What is the reference standard deviation for the adjustment?
- Tabulate the adjusted observations and their residuals.




Figure 11.5