

$$\underline{A} = \underline{L} \underline{L}^T$$

$\underline{A}$  معلوم و  $\underline{L}$  دا می بایست پیدا کرد :

$$\begin{bmatrix} a_{11} & a_{12} & a_{13} & a_{14} \\ a_{21} & a_{22} & a_{23} & a_{24} \\ a_{31} & a_{32} & a_{33} & a_{34} \\ a_{41} & a_{42} & a_{43} & a_{44} \end{bmatrix} = \begin{bmatrix} 1_{11} & & & \\ 1_{21} & 1_{22} & & \\ 1_{31} & 1_{32} & 1_{33} & \\ 1_{41} & 1_{42} & 1_{43} & 1_{44} \end{bmatrix} x$$

$$\begin{bmatrix} 1_{11} & 1_{12} & 1_{13} & 1_{14} \\ 1_{22} & 1_{23} & 1_{24} & \\ 1_{33} & 1_{34} & & \\ 1_{44} & & & \end{bmatrix}$$

با انجام ضرب سمت راست تساوی و مساوی قرار دادن عناصر

نظیر دو ماتریس داریم :

$$a_{11} = 1_{11}^2$$

$$\Rightarrow 1_{11} = (a_{11})^{1/2}$$

$$a_{21} = 1_{21} 1_{11}$$

$$\Rightarrow 1_{21} = a_{21} / 1_{11}$$

$$a_{31} = 1_{31} 1_{11}$$

$$\Rightarrow 1_{31} = a_{31} / 1_{11}$$

$$a_{41} = 1_{41} 1_{11}$$

$$\Rightarrow 1_{41} = a_{41} / 1_{11}$$

$$a_{22} = 1_{21}^2 + 1_{22}^2$$

$$\Rightarrow 1_{22} = (a_{22} - 1_{21})^{1/2}$$

$$a_{32} = 1_{31} 1_{21} + 1_{32} 1_{22}$$

$$\Rightarrow 1_{32} = (a_{32} - 1_{31} 1_{21}) / 1_{22}$$

$$a_{42} = 1_{41} 1_{21} + 1_{42} 1_{22}$$

$$\Rightarrow 1_{42} = (a_{42} - 1_{41} 1_{21}) / 1_{22}$$

$$a_{33} = 1_{31}^2 + 1_{32}^2 + 1_{33}^2$$

$$\Rightarrow 1_{33} = (a_{33} - 1_{31}^2 - 1_{32}^2)^{1/2}$$

$$a_{43} = 1_{41} 1_{31} + 1_{42} 1_{32} + 1_{43} 1_{33}$$

$$\Rightarrow 1_{43} = (a_{43} - 1_{41} 1_{31} - 1_{42} 1_{32}) / 1_{33}$$

$$a_{44} = l_{41}^2 + l_{42}^2 + l_{43}^2 + l_{44}^2 \Rightarrow l_{44} = (a_{44} - l_{41}^2 - l_{42}^2 - l_{43}^2)^{1/2}$$

$$\underline{\underline{L}} \underline{\underline{O}} = \underline{\underline{I}}$$

مرحلة دوم :

$$\begin{bmatrix} l_{11} & & & \\ l_{21} & l_{22} & & \\ l_{31} & l_{32} & l_{33} & \\ l_{41} & l_{42} & l_{43} & l_{44} \end{bmatrix} \times \begin{bmatrix} o_{11} & & & \\ o_{21} & o_{22} & & \\ o_{31} & o_{32} & o_{33} & \\ o_{41} & o_{42} & o_{43} & o_{44} \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}$$

با انجام ضرب سمت چپ تساوی و مساوی قرار دادن عناصر

خطیر داریم :

$$l_{11} o_{11} = 1 \Rightarrow o_{11} = 1/l_{11}$$

$$l_{22} o_{22} = 1 \Rightarrow o_{22} = 1/l_{22}$$

$$l_{33} o_{33} = 1 \Rightarrow o_{33} = 1/l_{33}$$

$$l_{44} o_{44} = 1 \Rightarrow o_{44} = 1/l_{44}$$

$$l_{21} o_{11} + l_{22} o_{21} = 0 \Rightarrow o_{21} = -o_{22} (l_{21} o_{11})$$

$$l_{31} o_{11} + l_{32} o_{21} + l_{33} o_{31} = 0 \Rightarrow o_{31} = -o_{33} (l_{31} o_{11} + l_{32} o_{21})$$

$$l_{41} o_{11} + l_{42} o_{21} + l_{43} o_{31} + l_{44} o_{41} = 0$$

$$\Rightarrow o_{41} = -o_{44} (l_{41} o_{11} + l_{42} o_{21} + l_{43} o_{31})$$

$$l_{32} o_{22} + l_{33} o_{32} = 0 \Rightarrow o_{32} = -o_{33} (l_{32} o_{22})$$

$$l_{42} o_{22} + l_{43} o_{32} + l_{44} o_{42} = 0 \Rightarrow o_{42} = -o_{44} (l_{42} o_{22} + l_{43} o_{32})$$

$$l_{43} o_{33} + l_{44} o_{43} = 0 \Rightarrow o_{43} = -o_{44} (l_{43} o_{33})$$

$$\underline{\underline{B}} = \underline{\underline{o}}^T$$

مرحلة سوم :

$$\begin{bmatrix} b_{11} & b_{12} & b_{13} & b_{14} \\ b_{21} & b_{22} & b_{23} & b_{24} \\ b_{31} & b_{32} & b_{33} & b_{34} \\ b_{41} & b_{42} & b_{43} & b_{44} \end{bmatrix} = \begin{bmatrix} o_{11} & o_{12} & o_{13} & o_{14} \\ o_{21} & o_{22} & o_{23} & o_{24} \\ o_{31} & o_{32} & o_{33} & o_{34} \\ o_{41} & o_{42} & o_{43} & o_{44} \end{bmatrix} \times \begin{bmatrix} l_{11} & & & \\ l_{21} & l_{22} & & \\ l_{31} & l_{32} & l_{33} & \\ l_{41} & l_{42} & l_{43} & l_{44} \end{bmatrix}$$

$$\begin{aligned}
 b_{11} &= o_{11}^2 + o_{21}^2 + o_{31}^2 + o_{41}^2 \\
 b_{21} &= o_{22}^2 o_{21} + o_{32}^2 o_{31} + o_{42}^2 o_{41} \\
 b_{31} &= o_{33}^2 o_{31} + o_{43}^2 o_{41} \\
 b_{41} &= o_{44}^2 o_{41} \\
 b_{12} &= b_{21} \\
 b_{22} &= o_{22}^2 + o_{32}^2 + o_{42}^2 \\
 b_{32} &= o_{33}^2 o_{32} + o_{43}^2 o_{42} \\
 b_{42} &= o_{44}^2 o_{42} \\
 b_{13} &= b_{31} \\
 b_{23} &= b_{32} \\
 b_{33} &= o_{33}^2 + o_{43}^2 \\
 b_{43} &= o_{44}^2 + o_{43}^2 \\
 b_{14} &= o_{41}^2 \\
 b_{24} &= o_{41}^2 \\
 b_{34} &= o_{43}^2 \\
 b_{44} &= o_{44}^2
 \end{aligned}$$

## سیاست

- 1, Ayres, F. (1962). Theory and Problems of Matrices.  
Schaum's outline Series, McGraw-hill, Toronto.
- 2, Thompson, E. H. (1969). Introduction to the Algebra of  
Matrices with some Applicationso University of  
Toronto Press.
- 3, Rao, C. R., and Mitra, S. K. (1971). Generalized Inverse  
of Matrices and Its Applications, John Wiley & Sons  
, New York.
- 4, Kurosh, A. (1980). Higher Algebra, Mir Publishers,  
Moscow.
- 5, Jaggi, V. P. and Mathur, A. B. (1985). Advanced Engineering  
Mathematics, Khanna Publishers, Delhi.

## فصل دوم

سرشکنی کمترین مرباعات

(مطلوب مقدماتی و پایه)

## ۱/۲- مراحل انجام یک پروژه نقشهبرداری

اکثر فعالیت‌های که نقشهبردار در قالب وظایف حرفه‌ای خود انجام می‌دهد نیازمند اندازه‌گیری است. جامعه به صورت سنتی به نقشهبردار به دیده فردی ماهر و متخصص در اندازه‌گیری زمین و عوارض مصنوعی و طبیعی موجود بر آن می‌نگرد. بدین خاطر از او انتظار جمع‌آموری اطلاعات هندسی زمینی را دارد. بالطبع این خواسته نیازمند اندازه‌گیری و به کار گیری آنها در فرمولهای ریاضی است.

اندازه‌گیری به مفهوم واقعی چیزی بیش از آن است که به نظر می‌آید. اگرچه از دیدگاه یک اپراتور ممکن است اندازه‌گیری تماماً به عملیات صحرائی محدود شود، اما یک فرد متخصص لازم است دیدی عمیق‌تر داشته و اندازه‌گیری‌های صحرائی را تنها بخوبی از کاد اندازه‌گیری و قدمی در جهت تامین اطلاعات مورد نیاز مراحل بعدی به حساب آورد. به علاوه پیش از شروع به اندازه‌گیری صحرائی لازم است مراحل و چگونگی انجام مشاهدات با توجه به هدف امکانات و دقت‌های که نهایتاً مورد نیاز می‌باشد طراحی کردد.

با چنین نگرشی است که می‌توان مراحل عملیات اجرائی یک پروژه نقشهبرداری را به درستی درک کرد. در نهایین کنفرانس استادان نقشهبرداری آمرایکای شمالی چنین بیان گردید:

"اندازه‌گیری بخشی از مراحل سرشکنی و آشاییز مشاهدات است"

(نگاره ۱). وثیچک و کرافسکی در کتاب خود [۲] جزئی از این

مراحل را در قالب عملیات ژئودزی کشیده اند .

به هر حال مراحل انجام یک پروژه نقشه برداری (نقشه برداری به مفهوم عام خود که شامل کلیه شاخه های آن میگردد) را میتوان به صورت زیر خلاصه کرد .

۱- اولین مرحله شناخت کمیتهای مجهول و دقت آنها است .

۲- مرحله بعدی یافتن مدلی است که به کمک آن بتوان به از طریق کمیتهای قابل اندازه کیری به کمیتهای مجهول رسید ( این مدل را اصطلاحاً مدل ریاضی می نامیم ) . لزوم وجود این مرحله از آنچاست که غالباً امکان اندازه کیری مستقیم کمیتهای مجهول وجود ندارد .

۳- قبل از شروع عملیات می بایست نحوه انجام مشاهدات را طراحی کرد . این عمل را اصطلاحاً تجزیه و تحلیل اولیه ( Preanalysis ) می نامیم .

۴- پس از انجام طراحی ، مشاهدات بر اساس دستور العمل تعیین شده در مرحله طراحی ( مرحله ۳ ) انجام میگیرد .

۵- بعد از انجام مشاهدات بلافاصله محاسبات اولیه آغاز میگردد . این محاسبات برای دو منظور اساسی صورت میگیرند ، کنترل مشاهدات از نظر وجود اشتباه یا خطای سیستماتیک و حذف آن و دیگر کنترل دقت مشاهدات ، اینکه آیا مشاهدات با دقت پیش بینی شده در طرح انجام گرفته اند ؟ یا خیر ؟

۶- در این مرحله اطلاعات جمع آوری شده به مدل های ریاضی معرفی و کمیتهای مجهول محاسبه میگردند .

۷- پس از محاسبه کمیتهای مجهول نوبت به بررسی و کنترل کیفیت نتایج میرسد . برای این منظور آزمون های آماری متعددی ترتیب

داده خواهد شد.

۸- مرحله نهائی ارائه اطلاعات به فرم قابل استفاده به مقاضی است.

همانگونه که در نکاره ۱ ملاحظه می‌گردد تنها در مرحله هفت است که می‌توان مشخص ساخت که آیا نیاز به اندازه‌گیری مجدد و بازگشت به مرحله یک وجود دارد؟ یا خیر؟ در این مرحله ممکن است لازم شود که حتی در مدل ریاضی و طراحی تجدید نظر کنیم.

## ۲/۲- پردازش اولیه اطلاعات

از نکات بسیار مهم در به کار گیری روش کمترین مربوطات حذف کلیه خطاهای سیستماتیک و اشتباهات قبل از سرشکنی است. چرا که همانگونه در بخش‌ای بعدی این فصل خواهید دید جوابی که از طریق این روش برای مجهولات حاصل می‌گردد هنگامی شاید از (Unbiased) خواهد بود که مشاهدات تنها دارای خطای اتفاقی بوده و عاری از هر کوته اشتباه یا خطای سیستماتیک باشد. به علاوه چون هزینه انجام مشاهدات بالا است. تکرار مشاهدات بعد از خروج اکیپهای مشاهده از صحراء شدیدا غیر اقتصادی می‌باشد.

بدین خاطر در وله اول روش انجام مشاهدات بایستی به کوته‌ای باشد که به صور مختلف وجود اشتباهات را کنترل کند. به علاوه لازم است در صحراء در حین و بلافاصله بعد از انجام مشاهده

کنترل‌های محاسباتی ساده‌ای چون مقایسه نتایج حاصل از تکرار با یکدیگر و برقراری شروط هندسی و ریاضی موجود بین مشاهدات انجام پذیرد.

به این محاسبات و کنترلها پردازش اولیه (یا Pre-processing) اطلاق می‌گردد. مجموعه اعمالی که تحت این عنوان صورت می‌گیرند محدوده وسیع دارند. بطوری که امروزه حتی امکان سرشکنی مقدماتی مشاهدات با کامپیوتراهای قابل حمل در صحراء وجود دارد. به این ترتیب می‌توان از صحت و دقیق نتایج نیز مطمئن شد. به علاوه در صورت نیاز به امکانات کامپیوترا بیشتر ارسال این اطلاعات از طریق خط تلفن به دفتر مرکزی و انجام محاسبات نهایی پیش از ترک اکیپهای مشاهده از منطقه عملیات میسر است.

### ۲/۳- علت نیاز به سرشکنی (سرشکنی مدل پارامتریک خطی)

- به سه دلیل در اندازه‌گیری به حداقل مشاهدات لازم اکتفا نمی‌گردد:
- ایجاد امکان کشف اشتباه (تنها راه کشف اشتباه تکرار است).
  - رسیدن به برآورد نزدیک به واقع از پارامترهای مجهول (هر مشاهده به منزله یک عضو از جوامعه با بینهایت عضو است، بنابر این هر چه تعداد اعضاء نمونه بیشتر باشد، امکان نتیجه‌گیری بر

مبانی اعفاء نادر جامعه کمتر خواهد شد).

- ایجاد امکان برآورد دقت اندازهگیری و نتایج حاصل.

فرض کنید وابطه بین مشاهدات و مجهولات بمورت زیر باشد:

$$l = Ax \quad (1)$$

x بودار مجهولات ، l بودار مشاهدات و A ماتریس ضرائب مجهولات است. به معادلاتی به شکل فوق، معادلات پارامتریک یا معادلات مشاهدات (Parametric Equations Observations Equations) یا مشاهده برای حل دستگاه و یافتن مجهولات از طریق معادلات (1) کافی خواهد بود. اما به دلایل ذکر شده اکتفای به حداقل مشاهدات لازم، صحیح نیست. لذا این تعداد مشاهدات (یا معادلات) (n) را بیش از تعداد مجهولات افزایش می‌دهیم. اما از آنجایی که مشاهدات بالطبع آلوده به خطاهای اتفاقی‌اند (البته پس از حذف اشتباهات و خطاهای سیستماتیک) معادلات ناسازگار شده و لذا جواب نخواهد داشت. چون :

$$D = \begin{bmatrix} A & l \\ (n^*u) & (n^*1) & [n^*(u+1)] \end{bmatrix} \quad \text{ماتریس بسط داده شده}$$

$$\text{rank}(D) = u+1 \quad \text{(شرط آنکه ستونهای } A \text{ صفر و یا وابسته نباشند)}$$

$$\text{rank}(A) = u \quad \text{(شرط وابسته یا صفر نبودن ستونهای } A \text{)}$$

$$\Rightarrow \text{rank}(A) \neq \text{rank}(D)$$

و بنابراین آنچه که در فصل (1) در مورد تعداد جوابهای یک دستگاه ذکر شد، معادلات (1) ناسازگار بوده و قادر جواب ندارند. تنها راه خروج از وضعیت حاصل و یافتن نوعی جواب برای (1)

پذیرش آنوده به خط بودن مشاهدات و اقدام به تصحیح آنهاست،  
یعنی افزودن بردار مجهول  $v$  به معادلات (۱) :

$$v+1 = Ax \quad (2)$$

و این آغاز مبحث سرگشتنی (یا Adjustment) است . بردار  
 $v$  ، بردار تصحیحات یا باقیماندهای (Residuals) کفته می شود .  
دستگاه معادلات (۲) که به آن دستگاه معادلات تغییر شکل یافته  
است . (اطلاق میگردد دارای بیانیت جواب Reformulated Equations)  
چون با توجه به مجهولات جدید ، معادله (۲) را میتوان  
به شکل زیر نوشت .

$$l = [A - I] \begin{bmatrix} x \\ v \end{bmatrix} = N \begin{bmatrix} x \\ v \end{bmatrix}$$

حال برای تعیین تعداد جواب ،  $\text{rank}(D)$  (ماتریس بسط داده شده )  
را با  $\text{rank}(N)$  (ماتریس ضرائب جدید) مقایسه میکنیم .

$$\text{rank}(N) = \text{rank}[A - I] = n \quad (\text{چون } \det(-I) \neq 0 \text{ است})$$

$$\text{rank}(D) = \text{rank}[A - I \ l] = n \quad (" " " ")$$

اما تعداد مجهولات  $n+1$  است (بردار مجهولات شامل  $x$  و  $v$  است ).  
بنابراین دستگاه (۲) بیانیت جواب خواهد دارد . نکته قابل  
توجه آنستکه  $l$  بردار مشاهدات بوده و تصحیح آن به هر مقدار جایز  
نیست . اگر برای این تصحیحات شرط

$$v^T v = \sum_{i=1}^n v_i^2 = \min \quad (3)$$

را قائل شویم اولاً تهایک  $x$  دارای این خاصیتی است که  $v$  های  
حتماً میتوانند در شرط (۳) صدق کنند و بعلاوه به این ترتیب  
مشاهدات را با مقادیری تصحیح کرده ایم که مجموع مربعات آنها

حداقل است . به این جواب ، جواب کمترین مربعات (Least Squares) می‌شود . توجه داشته باشید که میتوان برای باقیماندها اطلاق نمایی نداشت . شرط (۳) را نیز در نظر گرفت ، اما در آنصورت به جواب حاصل جواب کمترین مربعات گفته شواهد شد . یکی از شروطی که میتواند جایگزین شرط کمترین مربعات شرط ذیل است .

$$\sum_{i=1}^n |v_i| = \min$$

به جواب حاصل از این شرط جواب پسندیدار (Robust) گفته می‌شود چون کمتر تحت تاثیر خطای سیستماتیک و اشتباهات است . برای بدست آوردن  $\underline{x}$  هایی که شرط (۳) را برآورده می‌سازند ، از (۴) ثابت به بردار  $\underline{x}$  مشتق گرفته مساوی صفر قرار می‌دهیم .

$$\begin{aligned} \frac{d(\underline{v}^T \underline{v})}{d\underline{x}} &= \frac{d(\underline{A}\underline{x}-\underline{l})^T (\underline{A}\underline{x}-\underline{l})}{d\underline{x}} \\ &= \left( \frac{d(\underline{A}\underline{x}-\underline{l})^T}{d(\underline{A}\underline{x}-\underline{l})} \right) \left( \frac{d(\underline{A}\underline{x}-\underline{l})}{d\underline{x}} \right) \\ &= 2(\underline{A}\underline{x}-\underline{l})^T \underline{A} = 0 \end{aligned}$$

در صورتیکه ستونهای ماتریس  $\underline{A}$  صفر یا وابسته نباشند آنگاه

$(\underline{A}^T \underline{A})$  غیر مجرد بوده و داریم :

$$\underline{\hat{x}} = (\underline{A}^T \underline{A})^{-1} \underline{A}^T \underline{l} \quad (4)$$

گفته شد که اگر ماتریس  $\underline{A}$  دارای ستونهای وابسته و صفر نباشد  $(\underline{A}^T \underline{A})$  غیر مجرد است . برای اثبات این مطلب  $\underline{A}$  را بصورت زیر می‌نویسیم :

$$A = \begin{bmatrix} a_{11} & \dots & a_{1u} \\ \vdots & \ddots & \vdots \\ a_{n1} & \dots & a_{nu} \end{bmatrix} = [a_1 \dots a_u]$$

و در نتیجه  $\underline{\underline{A}}^T \underline{\underline{A}}$  بصورت زیر قابل محاسبه است:

$$\underline{\underline{A}}^T \underline{\underline{A}} = \begin{bmatrix} T & T & \dots & T \\ a_{-1-1} & a_{-1-2} & \dots & a_{-1-u} \\ \vdots & \vdots & \ddots & \vdots \\ T & T & \dots & T \\ a_{-u-1} & a_{-u-2} & \dots & a_{-u-u} \end{bmatrix}$$

که دترمینان آن تنها هنگامی مساوی صفر است که یکی از بردارهای  $a_{-1}, \dots, a_{-u}$  مساوی صفر و یا وابسته باشند.

تمرین :

نشان دهید در صورتیکه دو ستون  $\underline{\underline{A}}$  وابسته باشند (وابستگی خطی داشته باشند)  $\det(\underline{\underline{A}}^T \underline{\underline{A}}) = 0$  است.

برای بررسی آنکه جواب حاصل از (۴) ماقزیم کننده  $(\underline{\underline{v}}^T \underline{\underline{v}})$  است، یا مینیمم کننده آن، علامت مشتق دوم آنرا به ازای  $\underline{x}$  مورد بررسی قرار می‌دهیم.

$$\phi = \underline{\underline{v}}^T \underline{\underline{v}} = (\underline{\underline{A}} \underline{\underline{x}} - \underline{\underline{1}})^T (\underline{\underline{A}} \underline{\underline{x}} - \underline{\underline{1}})$$

$$\frac{d\phi}{dx} = \frac{d\underline{\underline{v}}}{d(\underline{\underline{A}} \underline{\underline{x}} - \underline{\underline{1}})} = \frac{d(\underline{\underline{A}} \underline{\underline{x}} - \underline{\underline{1}})}{dx} = 2(\underline{\underline{A}} \underline{\underline{x}} - \underline{\underline{1}})^T \underline{\underline{A}} \\ = 2(\underline{\underline{x}}^T \underline{\underline{A}}^T - 1^T) \underline{\underline{A}} = 2(\underline{\underline{x}}^T \underline{\underline{A}}^T \underline{\underline{A}} - 1^T \underline{\underline{A}})$$

$$\frac{d^2\phi}{dx^2} = 2 \underline{\underline{A}}^T \underline{\underline{A}}$$

حال بایستی علامت  $\underline{\underline{A}}^T \underline{\underline{A}}$  را تعیین کرد. یک ماتریس مرربع  $u \times u$  است، و تعیین علامت آن از طریق تعیین علامت مقادیر ویژه آن میسر است. بنابر فرضی که برای وجود جواب (۱) کرده‌ایم:

$$\underline{\underline{A}} = [ \underline{\underline{a}}_1 \quad \underline{\underline{a}}_2 \quad \cdots \quad \underline{\underline{a}}_u ]$$

بطوریکه  $\underline{\underline{a}}_1, \dots, \underline{\underline{a}}_u$  مستقل‌اند.

$$\underline{\underline{A}}^T \underline{\underline{A}} = \begin{bmatrix} \underline{\underline{a}}_1^T \\ \underline{\underline{a}}_2^T \\ \vdots \\ \vdots \\ \underline{\underline{a}}_u^T \end{bmatrix} [\underline{\underline{a}}_1 \quad \underline{\underline{a}}_2 \quad \cdots \quad \underline{\underline{a}}_u] = \begin{bmatrix} \underline{\underline{a}}_1^T \underline{\underline{a}}_1 & \cdots & \underline{\underline{a}}_1^T \underline{\underline{a}}_u \\ \vdots & \ddots & \vdots \\ \vdots & \cdots & \vdots \\ \underline{\underline{a}}_u^T \underline{\underline{a}}_1 & \cdots & \underline{\underline{a}}_u^T \underline{\underline{a}}_u \end{bmatrix} \quad (5/2)$$

ماتریس (۵) کلیه مقادیر ویژه‌اش مشبّت‌اند، چون اولاً بخطاطر مستقل بودن  $\underline{\underline{a}}_1, \dots, \underline{\underline{a}}_u$  غیر مجرد بوده و بعلاوه مقادیر روی قطر اصلی آن مرربع کامل‌اند. بنابر این  $\underline{\underline{A}}^T \underline{\underline{A}}$  یک ماتریس مشبّت بوده و جواب حاصل از (۴) می‌باشیم کنندۀ شرط (۳) است. به ماتریسی که تمام مقادیر ویژه آن مشبّت باشد، اکیداً مشبّت (Positive Definite).

ماتریس (۶) یک تنسور متريک (Metrix Tensor) برای فضای مجهولات است، چون مستقل بودن  $\underline{\underline{a}}_1, \dots, \underline{\underline{a}}_u$  بیانکر اين است که  $\underline{\underline{a}}_1, \dots, \underline{\underline{a}}_u$  یک مجموعه بردار پایه (Basis) برای فضای مجهولات می‌باشد و بعلاوه عناصر روی قطر اصلی  $\underline{\underline{A}}^T \underline{\underline{A}}$  ضرب داخلی بردارهای پایه در یکدیگر و عناصر خارج قدر اصلی حاصلضرب بردارهای پایه در یکدیگر ند.

## ۲/۴- سرشکنی همراه با وزن

جوابی که برای مجهولات بدست آوردهیم جوابی برای حالتی خاص بود. حالتی که در آن کلیه مشاهدات ارزش و اعتبار یکسانی داشتند و در نتیجه ملاک تعیین جواب شرط  $\underline{v}^T \underline{P} \underline{v} = \text{Min}$  بود. اما اگر مشاهدات دارای ارزش‌های مختلف باشند. این ارزشها را می‌توان بر حسب اعدادی که نشان دهنده دقت نسبی مشاهدات است در داخل ماتریس قطری  $\underline{P}$  قرارداد.

$$\underline{P} = \begin{bmatrix} p_1 & 0 & \dots & 0 \\ 0 & p_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & p_n \end{bmatrix}$$

$p_1, p_2, \dots, p_n$  دقت نسبی مشاهداتند و  $\underline{P}$  را ماتریس وزن می‌نامیم. حال برای آنکه دقت و ارزش مشاهدات را در تعیین جواب محفوظ داریم، شرط ذیل را به مدل پارامتریک تغییر یافته  $(\underline{v} + \underline{l} = \underline{A} \underline{x})$

می‌افزاییم:

$$\underline{v}^T \underline{P} \underline{v} = \text{Min}$$

به این ترتیب مشاهده با ارزش یا وزن بیشتر، تصحیح کمتری خواهد پذیرفت.

$$\phi = \underline{v}^T \underline{P} \underline{v} = (\underline{A} \underline{x} - \underline{l})^T \underline{P} (\underline{A} \underline{x} - \underline{l}) \quad (6)$$

برای رسیدن به جواب مینیمم برای  $\phi$  از (6) نسبت به  $\underline{x}$  مشتق

کرفته مساوی صفر قرار می‌دهیم:

$$\frac{d\phi}{dx} = \frac{d\phi}{d(Ax-1)} \times \frac{d(Ax-1)}{dx} = (Ax-1)^T P A = 0$$

$$(A^T P A)x = A^T P 1$$

و در صورتیکه  $P$  و  $A$  کمبود مرتبه نداشته باشند:

$$\hat{x} = (A^T P A)^{-1} A^T P 1 \quad (7)$$

کمبود مرتبه نداشتن  $A$  مستلزم مستقل بودن ستونهای آن و در مورد  $P$  عدم وجود عناصر صفر روی قطر اصلی است (یعنی  $P$  داپایستی بصورت ماتریسی قطری با عناصر قطر مخالف صفر انتخاب کنیم). برای بررسی می‌بینیم کننده بودن  $\hat{x}$  از (6) نسبت به  $x$  دو بار

مشتق می‌گیریم:

$$\frac{d^2\phi}{dx^2} = 2A^T P A \quad (8)$$

برای آنکه مقادیر ویژه (8) همواره مشتبه باشند می‌بایست  $A$  کمبود مرتبه نداشته و بعلاوه عناصر قطری  $P$  مشتبه باشند. بنابر این وزنهای که برای مشاهدات انتخاب می‌کنیم بایستی مشتبه و مخالف صفر باشند.

بعد از برآورد  $\hat{x}$  از رابطه (7) امکان برآورد باقیمانده‌ها

نیز وجود خواهد داشت:

$$v = Ax-1 \quad \hat{v} = \hat{A}\hat{x}-1 \\ = \hat{A}(A^T P A)^{-1} A^T P 1 - 1 \quad (9)$$

بر اساس آنچه که تاکنون اثبات گردید،

$$\hat{\underline{x}} = (\underline{A}^T \underline{P} \underline{A})^{-1} \underline{A}^T \underline{P} \underline{l}$$

$$\underline{v} + \underline{l} = \underline{A} \hat{\underline{x}}$$

برآورد کمترین مربعات مدل

است. حال میخواهیم ثابت کنیم که :

$$E(\hat{\underline{x}}) = \underline{x}$$

(۱۰)

یعنی  $\hat{\underline{x}}$  یک برآورد نااریب (Unbiased) از  $\underline{x}$  مجهول معادله (۲)

است. برای اثبات این مطلب از (۷) امید ریاضی میگیریم :

$$\begin{aligned} E(\hat{\underline{x}}) &= E[(\underline{A}^T \underline{P} \underline{A})^{-1} \underline{A}^T \underline{P} \underline{l}] \\ &= (\underline{A}^T \underline{P} \underline{A})^{-1} \underline{A}^T \underline{P} E(\underline{l}) \end{aligned}$$

(۱۱)

از طرفی با توجه به (۲) :

$$\underline{l} = \underline{A} \underline{x} - \underline{v}$$

(۱۲)

بنابراین اگر نتیجه (۱۲) را در (۱۱) قرار دهیم :

$$E(\hat{\underline{x}}) = (\underline{A}^T \underline{P} \underline{A})^{-1} \underline{A}^T \underline{P} E(\underline{A} \underline{x} - \underline{v})$$

(۱۳)

$$= (\underline{A}^T \underline{P} \underline{A})^{-1} \underline{A}^T \underline{P} \underline{A} \underline{x} - E(\underline{v})$$

(۱۴)

$$= \underline{x} - E(\underline{v})$$

اگر مشاهدات ماری از اشتباه و خطای سیستماتیک باشند،

(تنها تحت تاثیر خطاهای اتفاقی باشند) در مدل (۲)  $\underline{v}$  خطای

اتفاقی مشاهدات بوده لذا  $E(\underline{v})=0$  خواهد شد و از (۱۴) نتیجه می‌کیریم که :

(در صورت عدم وجود اشتباه و خطای سیستماتیک)  $\hat{E}(\underline{x}) = \underline{x}$  که باعث تکمیل اثبات می‌گردد.

## ۴/۲- ماتریس کووریانس باقیماندها

طبق تعریف ماتریس کووریانس، در مورد باقیمانده هاداریم:

$$\underline{C}_{\underline{v}} = E[(\underline{v} - E(\underline{v})) (\underline{v} - E(\underline{v}))^T] \quad (15)$$

در صورتیکه مشاهدات تنها دارای خطای انتقامی باشند،

$E(\underline{v}) = 0$  بوده و در نتیجه:

$$\underline{C}_{\underline{v}} = E(\underline{v} \underline{v}^T) \quad (16)$$

اما با توجه به مدل (۲)،

$$\underline{v} = \underline{A} \underline{x} - \underline{l} \quad (17)$$

با اعمال اپراتور  $E$  (امید ریاضی) به طرفین تساوی (۱۷) داریم:

$$E(\underline{l}) = \underline{A} \underline{x} \quad (18)$$

حال اگر در (۱۷) بجای  $\underline{A} \underline{x}$  مقدار متساوی آنرا از (۱۸) قرار دهیم،

$$\underline{v} = E(\underline{l}) - \underline{l} \quad (19)$$

و نهایتاً،

$$\underline{C}_{\underline{v}} = E[(E(\underline{l}) - \underline{l})(E(\underline{l}) - \underline{l})^T] = \underline{C}_{\underline{l}} \quad (20)$$

یعنی ماتریس کووریانس مشاهدات با ماتریس کووریانس باقیماندها برابر است.

## ۲/۷- جواب حاصل از روش کمترین مربلات

### برآوردهای ماقزیم احتمال باقیماندها

اگر در مدل پارامتریک (۲) مشاهدات دارای تابع توزیع نرمال باشند،  $\underline{v}$  هم که تابعی خطی از  $\underline{v}$  است دارای تابع توزیع نرمال خواهد بود. پس در این حالت تابع توزیع چگالی باقیماندها به صورت ذیل خواهد بود.

$$f_{\underline{v}}(\underline{v}) = \frac{\left( \det(C^{-1}) \right)^{1/2}}{(2\pi)^{n/2}} \exp \left[ -\frac{1}{2} (\underline{v} - E(\underline{v}))^T C^{-1} (\underline{v} - E(\underline{v})) \right]$$

اگر مشاهدات فاقد خطای سیستماتیک باشند ( $E(\underline{v}) = 0$ )

$$f_{\underline{v}}(\underline{v}) = C \exp \left[ -\frac{1}{2} \underline{v}^T C^{-1} \underline{v} \right]$$

بنابر این جوابی که مینیمیم کننده  $(\underline{v}^T C^{-1} \underline{v})$  است ماقزیم کننده احتمال  $\underline{v}$  ها است. یعنی اگر در مدل پارامتریک  $(\underline{v} + \underline{A} \underline{x} = \underline{A} \underline{x})$  بخواهیم  $\underline{x}$  را بدست آوریم که برای آن  $\underline{v}$  احتمال ماقزیم داشته باشد باز هم به همان جواب کمترین مربلات خواهیم رسید. البته به شرط آنکه ماتریس وزن را عکس ماتریس کووریانس مشاهدات، و یا متناسب با عکس آن انتخاب کرده باشیم.

$$P = C^{-1} \quad \text{یا} \quad P \propto C^{-1}$$

متاسفانه عملاً ندرتاً پیش از سرشکنی ماتریس کووریانس مشاهدات قبل از سرشکنی مطور کامل در اختیار است. و در واقع یکی از اهداف سرشکنی یافتن برآوردهای برای ماتریس کووریانس

مشاهدات یا بطور کلی دقت مشاهدات می‌باشد.

اما همواره قبل از سرشکنی تشکیل ماتریسی که دقت نسبی مشاهدات را نشان دهد میسر است. به این ماتریس که با ماتریس کووریانس واقعی مشاهدات تنها در یک ضریب (یا مقیاس) متفاوت است، ماتریس کووریانس نسبی ( $\underline{Q}$ ) می‌گوئیم.

$$\underline{C} = \begin{pmatrix} 2 & 0 \\ -1 & 0 \end{pmatrix} \quad (21)$$

بنابراین حد اکثر می‌توان وزن مشاهدات عکس ماتریس کووریانس نسبی انتخاب کرد.

$$\underline{P} = \underline{Q}^{-1} \quad (22)$$

واضح است که این انتخاب بر روی نتیجه اخیر اثربخش می‌گذارد. اما ببینیم تاثیر آن بر جواب کمترین مربعات چگونه است.

قبل اثبات کردیم که :

$$\begin{aligned} \hat{\underline{x}} &= (\underline{A}^T \underline{P} \underline{A})^{-1} \underline{A}^T \underline{P} \underline{1} \\ &= (\underline{A}^T \underline{Q}^{-1} \underline{A})^{-1} \underline{A}^T \underline{Q}^{-1} \underline{1} \\ &= (\underline{A}^T \begin{pmatrix} 2 & 0 \\ -1 & 0 \end{pmatrix}^{-1} \underline{A})^{-1} \underline{A}^T \begin{pmatrix} 2 & 0 \\ -1 & 0 \end{pmatrix}^{-1} \underline{1} \\ &= (\underline{A}^T \begin{pmatrix} -1 & 0 \\ 0 & 1 \end{pmatrix}^{-1} \underline{A})^{-1} \underline{A}^T \begin{pmatrix} -1 & 0 \\ 0 & 1 \end{pmatrix}^{-1} \underline{1} \end{aligned}$$

یعنی نتیجه حاصل از سرشکنی همان خوبی است که از طریق انتخاب ماتریس وزن به صورت عکس ماتریس کووریانس مشاهدات (صورت دستیابی به آن) حاصل می‌گردد. بنابراین انتخاب وزن بصورت  $\underline{P} = \underline{Q}^{-1}$  یا  $\underline{P} = \underline{C}_{-1}^{-1}$  منجر به نتیجه یکسان برای مجهولات خواهد شد.

## ۲/۸- جواب حاصل از روش کمترین مربقات

### برآورده کننده می‌شیم و ریاضی

فرض می‌کنیم :

$$\underline{x} = \underline{B} \underline{l} \quad (23)$$

یک برآورده کننده ناواریب برای  $\underline{x}$  باشد.

در مدل  $\underline{v} + \underline{l} = \underline{A} \underline{x}$ ،  $\underline{x}$  یک بردار بوده و بنابر این مفهوم مینیمیم و ریاضی آن معادن تریس (Trace) می‌شیم برای  $\underline{x}$  است. پس هدف ما این است که برآورده کننده ناواریبی برای  $\underline{x}$  بدست آوریم که در مورد آن  $\text{trace}(\underline{C}^{\hat{x}}) = \min_{\underline{x}}$  باشد.

خاصیت شاریبی حکم می‌کند که:

$$E(\underline{x}) = \underline{x} \quad (24)$$

با اعمال اپراتور  $E$  بر (23) داریم:

$$E(\underline{x}) = E(\underline{B} \underline{l}) = \underline{B} E(\underline{A} \underline{x} - \underline{v}) = \underline{B} \underline{A} \underline{x}$$

بنابراین فرض ناواریبی در صورتی برقرار خواهد بود که  $\underline{B} \underline{A} = \underline{I}$  باشد.

حال قانون انتشار خطاهای را به وابطه (23) اعمال می‌کنیم.

$$\underline{C}^{\hat{x}} = \underline{B} \underline{C}_1 \underline{B}^T$$

اکنون  $\underline{B}$  را بگوئیم می‌یابیم که:

$$\text{Trace}(\underline{B} \underline{C}_1 \underline{B}^T)$$

مینیمیم شده و در عین حال شرط ناواریبی  $(\underline{B} \underline{A} - \underline{I} = \underline{0})$  برقرار باشد.

برای این منظور از روش لاکر انژ استفاده می‌کنیم :

$$\phi = \underline{\underline{B}} \underline{\underline{C}}_{-1}^T \underline{\underline{B}} + 2 (\underline{\underline{B}} \underline{\underline{A}} - \underline{\underline{I}}) \underline{k} = 0$$

k ماتریس با عناصر مجهول است که به آن ماتریس ضرایب لاکر انژ کفته می‌شود . (Lagrange multipliers)

بر اساس قواعد مشتق از Trace که در فصل (۱) نیز مرور گردید ،

داریم :

$$\text{Tr}(\phi) = \text{Tr}(\underline{\underline{B}} \underline{\underline{C}}_{-1}^T \underline{\underline{B}}) + 2 \text{Tr}(\underline{\underline{B}} \underline{\underline{A}} \underline{k}) - 2 \text{Tr}(\underline{k})$$

$$\frac{d \text{Tr}(\underline{\underline{B}} \underline{\underline{C}}_{-1}^T \underline{\underline{B}})}{d \underline{\underline{B}}} = \underline{\underline{C}}_{-1}^T (\underline{\underline{B}}^T + \underline{\underline{B}}^T) = 2 \underline{\underline{C}}_{-1}^T \underline{\underline{B}}^T$$

$$\frac{d \text{Tr}(\underline{\underline{B}} \underline{\underline{A}} \underline{k})}{d \underline{\underline{B}}} = \underline{\underline{A}} \underline{k}$$

$$\frac{d \text{Tr}(\underline{k})}{d \underline{\underline{B}}} = 0$$

$$\frac{d \text{Tr}(\phi)}{d \underline{\underline{B}}} = 2 \underline{\underline{C}}_{-1}^T \underline{\underline{B}} + 2 \underline{\underline{A}} \underline{k} = 0$$

$$\Rightarrow \underline{\underline{B}} = -\underline{k}^{-1} \underline{\underline{A}}^T \underline{\underline{C}}_{-1}^{-1}$$

چون  $\underline{\underline{B}} \underline{\underline{A}} = \underline{\underline{I}}$  است پس طرفین تساوی فوق را از داشت در  $\underline{\underline{A}}$  ضرب

کرده مساوی  $\underline{\underline{I}}$  ندار می‌دهیم :

$$\underline{k}^{-1} = -(\underline{\underline{A}} \underline{\underline{C}}_{-1}^T \underline{\underline{A}})^{-1} \quad \underline{\underline{B}} = (\underline{\underline{A}} \underline{\underline{C}}_{-1}^T \underline{\underline{A}})^{-1} \underline{\underline{A}} \underline{\underline{C}}_{-1}^{-1}$$

و شاید با :

$$\hat{\underline{x}} = \underline{B} \underline{l} = (\underline{A}^T \underline{C}^{-1} \underline{A})^{-1} \underline{A}^T \underline{C}^{-1} \underline{l}$$

با مقایسه این جواب با جواب حاصل از اعمال شرط کمترین مربعات به این نتیجه می‌رسیم که در صورتیکه  $\underline{C}^{-1} = \underline{P}$  انتخاب شود جواب حاصل از روش کمترین مربعات دادای کوچکترین وریانس خواهد بود. توجه داشته باشید که در صورت انتخاب وزن بصورت  $\underline{P} = \underline{Q}^{-1}$  همچنان نتیجه حاصل صحیح خواهد بود.

## ۲/۹- جواب کمترین مربعات مدل پارامتریک

### شبه معکوس

دو مدل پارامتریک  $(\underline{l} = \underline{A} \underline{x})$ ،  $\hat{\underline{x}}$  حاصل از (۷) جوابی منحصر به فرد برای  $\underline{x}$  است. از طرفی برای این مدل جواب دیل نیز منحصر به فرد است.

$$\hat{\underline{x}} = \underline{A}^+ \underline{l} \quad (25)$$

حال این سوال به ذهن متداول می‌گردد که آیا ارتباطی ضریب  $\underline{l}$  در رابطه (۷) شبه معکوس  $\underline{A}$  نیست؟

برای پاسخ به این سوال چهار خاصیت شبه معکوس را برای ضریب  $\underline{l}$  در رابطه (۷) یعنی:

$$\underline{B} = (\underline{A}^T \underline{P} \underline{A})^{-1} \underline{A}^T \underline{P} \quad (26)$$

امتحان می‌کنیم. شروط (i)، (ii) و (iv) شبه معکوس (رجوع کنید به فصل (۱)) به وضوح برقرارند، تنها در مورد شرط (iii) داریم:

$$(\underline{A} (\underline{A}^T \underline{P} \underline{A})^{-1} \underline{A}^T \underline{P})^T = \underline{P} \underline{A} (\underline{A}^T \underline{P} \underline{A})^{-1} \underline{A}^T \quad (27)$$

که تنها هنگامی برقرار خواهد بود که  $\underline{P} = \underline{I}$  باشد . یعنی اگر  $\underline{P} = \underline{I}$  باشد جواب حاصل از روش کمترین مربغات و جواب حاصل از  $(25)$  یکی خواهند بود .

این نتیجه دستورالعملی برای تعیین شبه معکوس ماتریسی‌ای مستطیلی با تعداد سطرهای بیش از ستون و فاقد کمبود مرتبه در اختیار می‌گذارد .

$$\underline{A}^+ = (\underline{A}^T \underline{A})^{-1} \underline{A}^T \quad (26)$$

## ۲/۱- ماتریس‌های کووریانس

### کمیتهای حاصل از سرشکنی مدل پارامتریک خطی

آنکوته که قبلاً گفته شد یکی از اهداف تکرار در اندازه‌گیری برآورد دقت (precision) مشاهدات و مجهولات است. بدین لحاظ در این بخش می‌خواهیم برآوردکننده‌هایی برای دقت کمیتهای حاصل از سرشکنی کمترین مربعات بدست آوریم. به این ترتیب انتقال آماری از فضای مشاهدات به مجهولات تکمیل می‌گردد (اطلاعات آماری فضای مشاهدات در  $\underline{C}_1$ ,  $\underline{1}$  نهفته می‌باشد).

قابل ذکر است که، بدست آوردن ماتریس کووریانس کمیتهای حاصل از سرشکنی، امکان بررسی‌های آماری گوناگون در مورد این کمیتها و برآوردهای فوائل اطمینان برای آنها را فراهم می‌آورد.

### ماتریس کووریانس مجهولات برآورده شده ( $\hat{\underline{x}}$ )

$$\begin{aligned} \text{با داشتن } \underline{C}_{\underline{x}} = \underline{B} \underline{C}_1 \underline{B}^T \text{ می‌خواهیم } \hat{\underline{x}} = \underline{B} \underline{1} \text{ بدست آوریم.} \\ \text{با اعمال قانون اشتشار خطاهای رابطه (۷) داریم:} \\ \underline{C}_{\underline{x}}^* = \left[ (\underline{A}^T \underline{P} \underline{A})^{-1} \underline{A}^T \right] \underline{C}_1 \left[ (\underline{A}^T \underline{P} \underline{A})^{-1} \underline{A}^T \right]^T \quad \dots(۲۹) \end{aligned}$$

که در آن  $\underline{P}$  برابر است با:

$$\underline{P} = \underline{Q}^{-1} = \underline{2} \underline{C}_1^{-1}$$

بنابراین (۲۹) را می‌توان به صورت ذیل نوشت:

$$\underline{C}_{\underline{x}}^* = \left[ (\underline{A}^T \underline{C}_1^{-1} \underline{A})^{-1} \right] \underbrace{\left[ \underline{A}^T \underline{C}_1^{-1} \underline{A}^T (\underline{A}^T \underline{C}_1^{-1} \underline{A})^{-1} \right]}_I$$

$$= \left( \underline{A}^T \underline{C}_1^{-1} \underline{A} \right)^{-1} \dots (29)$$

## ماتریس کووریانس تحقیقات برآورد شده (v)

با توجه به مدل دیاضی ( $v+1 = A x$ ) داریم :

$$\begin{aligned} \hat{v} &= \underline{A}^T \underline{x} - 1 \\ &= \underline{A} \left( \underline{A}^T \underline{P} \underline{A} \right)^{-1} \underline{A}^T \underline{P} \underline{1} - 1 \\ &= \left[ \underline{A} \left( \underline{A}^T \underline{P} \underline{A} \right)^{-1} \underline{A}^T \underline{P} \underline{I} \right] \underline{1} \end{aligned}$$

بنابر این :

$$\hat{C}_v = \left[ \underline{A} \left( \underline{A}^T \underline{P} \underline{A} \right)^{-1} \underline{A}^T \underline{P} \underline{I} \right] \underline{C}_1 \left[ \underline{P} \underline{A} \left( \underline{A}^T \underline{P} \underline{A} \right)^{-1} \underline{A}^T \underline{I} \right]$$

با در نظر گرفتن :

$$\underline{P} = \underline{Q}^{-1} = \underline{C}_1^2 \underline{C}_1^{-1}$$

داریم :

$$\begin{aligned} \hat{C}_v &= \left[ \underline{A} \left( \underline{A}^T \underline{C}_1^{-1} \underline{A} \right)^{-1} \underline{A}^T \underline{C}_1^{-1} \underline{I} \right] \underline{C}_1 \left[ \underline{C}_1^{-1} \underline{A} \left( \underline{A}^T \underline{C}_1^{-1} \underline{A} \right)^{-1} \underline{A}^T \underline{I} \right] \\ &= \left[ \underline{A} \left( \underline{A}^T \underline{C}_1^{-1} \underline{A} \right) \underline{A}^T \underline{C}_1 \right] \left[ \underline{C}_1^{-1} \underline{A} \left( \underline{A}^T \underline{C}_1^{-1} \underline{A} \right)^{-1} \underline{A}^T \underline{I} \right] \\ &= \underline{A} \left( \underline{A}^T \underline{C}_1^{-1} \underline{A} \right)^{-1} \underline{A}^T \underline{C}_1 + \underline{C}_1 = \underline{C}_1 - \underline{A} \left( \underline{A}^T \underline{C}_1^{-1} \underline{A} \right)^{-1} \underline{A}^T \dots (40) \end{aligned}$$

## ماتریس کووریانس مشاهدات برآورده شده ( $\hat{I}$ )

$$\hat{\underline{l}} = \underline{l} + \hat{\underline{v}} = \underline{A} \hat{\underline{x}}$$

$$\hat{\underline{C}}_1 = \underline{A} \underline{C}_1 \underline{A}^T = \underline{A} \left( \underline{A}^T \underline{C}_1^{-1} \underline{A} \right)^{-1} \underline{A}^T \quad \dots (31)$$

با مقایسه (۳۰) و (۳۱) به این نتیجه می‌رسیم :

$$\hat{\underline{C}}_{\underline{v}} = \underline{C}_1 - \hat{\underline{C}}_1 \quad \dots (32)$$


---

نکته حائز اهمیت در ماتریسمهای کووریانس حاصله، آن است که هیچکدام از آنها بستگی به مشاهدات و مقادیر آنها ندارد و همه آنها را تنها با اختیار داشتن  $\underline{C}_1$  و مدل ریاضی می‌توان بدست آورد. این مطلب از نقطه نظر طراحی بسیار با ارزش بوده و نکته مشبّتی به شمار می‌رود. چون پیش از انجام مشاهدات می‌توان بروزی کرد که آیادقت خواسته شده برای مجهولات قابل دستیابی است یا خیر. اما از طرفی دیگر در تمام این روابط  $\underline{C}_1$  مورد نیاز است در حالی که در شروع سرشکنی غالباً  $\underline{Q}$  در اختیار می‌باشد و رسیدن به برآورده از  $\underline{C}_1$  یکی از اهداف سرشکنی است.

خوبختانه همانگونه که قبله دیدید برآورد مقدار مجهولات

نیازی به آگاهی از مقدار صحیح  $\underline{C}_1$ <sup>2</sup> ندارد.

بنابر این  $\underline{x}_1$  و  $\hat{\underline{v}}$  بدون هیچگونه تاثیر پذیری از مقدار

استخوابی برای  $\underline{C}_1$ <sup>2</sup> بدست می‌آیند. پس از برآورد این کمیتها

اگر بتوانیم برآورده برای  $\underline{C}_1$ <sup>2</sup> بدست آوریم کمان می‌رود که مشکل

ماتریس‌های کووریانس نیز حل کردد.

## ۱۱- درجه آزادی

یکی از نکات اساسی و مهم قبل از سرشکنی یافتن رابطه بین مشاهدات و مجهولات است. به این رابطه همانطور که قبلاً گفته شد مدل ریاضی می‌کوئیم. با در اختیار داشتن نحوه ارتباط مشاهدات با مجهولات (مدل ریاضی) می‌توانیم مشخص کنیم که چند معادله برای تعیین مجهولات بصورت منحصر به فرد لازم است. اما همانگونه که پیشتر نیز گفته شد ما به این تعداد معادله اکتفا نمی‌کنیم چون به این ترتیب امکان پی‌بردن به اشتبااه، برآورد مقدار قابل اطمینان برای مجهولات و برآورد دقت اندازه گیری میسر نخواهد بود. بنابراین تعداد معادلات را عمداً بیشتر از مجهولات قرار می‌دهیم. به این تعداد معادلات اضافی درجه آزادی گفته می‌شود.

• (Degrees of freedom)

$$df = m - u \quad \dots \quad (33)$$

df : درجه آزادی

m : تعداد معادلات

u : تعداد مجهولات

در مدل پارامتریک اگر تعداد معادلات را  $n$  بنامیم، درجه آزادی چنین خواهد بود:

$$df = n - u \quad \dots \quad (34)$$

علت بکار بردن لفظ آزادی (یا درجه آزادی) بدین خاطر است

که هر اندازه تعداد معادلات بیشتر از تعداد مجهولات کردد توان یا

آزادی عمل ما در پی بردن به اشتباهات و برآورد بهتر برای کمیتهای مجهول بالاتر خواهد رفت . در مدل پارامتریک ، تغییرات درجه آزادی بین صفر تا تعداد مشاهدات است .

## ۱۲/برآورد وریانس وزن واحد

همانگونه که قبلاً کفته شد دستیابی به ماتریسهای کوریانس  $\hat{\sigma}_0^2$  و  $\frac{1}{n} \hat{x}^T P \hat{x}$  در اختیار باشد . اما چنین چیزی عملاً بشرط اتفاق می‌افتد . لذا می‌بایست بنحوی مقدار  $\hat{\sigma}_0^2$  را از طریق مشاهدات انجام شده برآورد کرد . یعنی به یک  $\hat{\sigma}_0^2$  دست یافت و از آن به جای  $\hat{x}^T P \hat{x}$  موجود در روابط مربوط به ماتریسهای کوریانس کمیتهای برآورد شده  $(\hat{v}, \hat{x})$  استفاده کرد . اما این برآورد کشته (Estimator) بایستی نااریب باشد .

نشان خواهیم داد که اولاً

$$\hat{\sigma}_0^2 = \frac{\hat{v}^T P \hat{v}}{n-u}$$

و در شانی این برآورد کشته نااریب است . یعنی :

$$E(\hat{\sigma}_0^2) = E\left[\frac{\hat{v}^T P \hat{v}}{n-u}\right] = \frac{1}{n-u} E(\hat{v}^T P \hat{v}) = \sigma_0^2$$

یا

$$E(\hat{v}^T P \hat{v}) = (n-u) \sigma_0^2 \quad \dots (35)$$

## اثبات

برای این مشکل از معادلات نرمال شروع می کنیم:

$$\underline{\underline{A}}^T \underline{\underline{P}} \underline{\underline{A}} \hat{\underline{\underline{x}}} = \underline{\underline{A}}^T \underline{\underline{P}} \underline{\underline{1}} \quad (36)$$

این دستگاه را می توان بصورت زیر نوشت:

$$\underline{\underline{A}}^T \underline{\underline{P}} (\hat{\underline{\underline{x}}} - \underline{\underline{1}}) = \underline{\underline{0}} \quad \text{یا} \quad (\hat{\underline{\underline{x}}} - \underline{\underline{1}})^T \underline{\underline{P}} \underline{\underline{A}} = \underline{\underline{0}} \quad (37)$$

$$\underline{\underline{A}}^T \underline{\underline{P}} \underline{\underline{A}} \hat{\underline{\underline{x}}} = \underline{\underline{A}}^T \underline{\underline{P}} \underline{\underline{1}} \quad \hat{\underline{\underline{x}}}^T \underline{\underline{A}}^T \underline{\underline{P}} \underline{\underline{A}} = \underline{\underline{1}}^T \underline{\underline{P}} \underline{\underline{A}}$$

بر اساس این تساوی می توان نشان داد:

$$\underline{\underline{v}}^T \underline{\underline{P}} \underline{\underline{v}} - \hat{\underline{\underline{v}}}^T \underline{\underline{P}} \hat{\underline{\underline{v}}} = (\hat{\underline{\underline{x}}} - \underline{\underline{x}})^T \underline{\underline{A}}^T \underline{\underline{P}} \underline{\underline{A}} (\hat{\underline{\underline{x}}} - \underline{\underline{x}})$$

چون:

$$\begin{aligned} \hat{\underline{\underline{v}}}^T \underline{\underline{P}} \hat{\underline{\underline{v}}} &= (\hat{\underline{\underline{x}}} - \underline{\underline{x}})^T \underline{\underline{P}} (\hat{\underline{\underline{x}}} - \underline{\underline{x}}) \\ &= (\hat{\underline{\underline{x}}} - \underline{\underline{x}})^T \underline{\underline{P}} \underline{\underline{A}} \hat{\underline{\underline{x}}} - \hat{\underline{\underline{x}}}^T \underline{\underline{A}}^T \underline{\underline{P}} \underline{\underline{1}} + \underline{\underline{1}}^T \underline{\underline{P}} \underline{\underline{1}} \end{aligned}$$

با متوجه به (37)

$$= \underline{\underline{1}}^T \underline{\underline{P}} \underline{\underline{1}} - \hat{\underline{\underline{x}}}^T \underline{\underline{A}}^T \underline{\underline{P}} \underline{\underline{A}} \hat{\underline{\underline{x}}} \quad (38)$$

و همچنین:

$$\begin{aligned} \underline{\underline{v}}^T \underline{\underline{P}} \underline{\underline{v}} &= (\hat{\underline{\underline{x}}} - \underline{\underline{x}})^T \underline{\underline{P}} (\hat{\underline{\underline{x}}} - \underline{\underline{x}}) \\ &= \hat{\underline{\underline{x}}}^T \underline{\underline{A}}^T \underline{\underline{P}} \underline{\underline{A}} - \underline{\underline{1}}^T \underline{\underline{P}} \underline{\underline{A}} \hat{\underline{\underline{x}}} - \hat{\underline{\underline{x}}}^T \underline{\underline{A}}^T \underline{\underline{P}} \underline{\underline{1}} + \underline{\underline{1}}^T \underline{\underline{P}} \underline{\underline{1}} \end{aligned}$$

$$\underline{\underline{1}}^T \underline{\underline{P}} \underline{\underline{A}} = \hat{\underline{\underline{x}}}^T \underline{\underline{A}}^T \underline{\underline{P}} \underline{\underline{A}} \quad \text{و} \quad \underline{\underline{A}}^T \underline{\underline{P}} \underline{\underline{1}} = \underline{\underline{A}}^T \underline{\underline{P}} \hat{\underline{\underline{x}}} \quad \text{اما}$$

$$= \hat{\underline{\underline{x}}}^T \underline{\underline{A}}^T \underline{\underline{P}} \underline{\underline{A}} \hat{\underline{\underline{x}}} - \hat{\underline{\underline{x}}}^T \underline{\underline{A}}^T \underline{\underline{P}} \underline{\underline{A}} \hat{\underline{\underline{x}}} - \hat{\underline{\underline{x}}}^T \underline{\underline{A}}^T \underline{\underline{P}} \underline{\underline{A}} \hat{\underline{\underline{x}}} + \underline{\underline{1}}^T \underline{\underline{P}} \underline{\underline{1}} \quad (39)$$

بنابراین از تفاضل (38) و (39) خواهیم داشت:

$$\begin{aligned} \underline{\underline{v}}^T \underline{\underline{P}} \underline{\underline{v}} - \hat{\underline{\underline{v}}}^T \underline{\underline{P}} \hat{\underline{\underline{v}}} &= \hat{\underline{\underline{x}}}^T \underline{\underline{A}}^T \underline{\underline{P}} \underline{\underline{A}} \hat{\underline{\underline{x}}} - \hat{\underline{\underline{x}}}^T \underline{\underline{A}}^T \underline{\underline{P}} \underline{\underline{A}} \hat{\underline{\underline{x}}} - \hat{\underline{\underline{x}}}^T \underline{\underline{A}}^T \underline{\underline{P}} \underline{\underline{A}} \hat{\underline{\underline{x}}} + \underline{\underline{1}}^T \underline{\underline{P}} \underline{\underline{1}} - \underline{\underline{1}}^T \underline{\underline{P}} \underline{\underline{1}} + \hat{\underline{\underline{x}}}^T \underline{\underline{A}}^T \underline{\underline{P}} \underline{\underline{A}} \hat{\underline{\underline{x}}} \\ &= (\hat{\underline{\underline{x}}} - \underline{\underline{x}})^T \underline{\underline{A}}^T \underline{\underline{P}} \underline{\underline{A}} (\hat{\underline{\underline{x}}} - \underline{\underline{x}}) \end{aligned}$$

در نتیجه:

$$\hat{v}^T \hat{P} \hat{v} = v^T P v - (\hat{x} - \bar{x})^T A^T P A (\hat{x} - \bar{x})$$

برای یک فرم مربعی (Quadratic) مانند  $\hat{y}^T A \hat{y}$  دادیم:

$$\text{Trace}(\hat{y}^T A \hat{y}) = \hat{y}^T A \hat{y}$$

و در مورد آن  $\text{Trace}$  بنا بر این:

$$\text{Tr}(\hat{y}^T A \hat{y}) = \text{Tr}(\hat{y}(\hat{y}^T A))$$

$$\hat{y}^T A \hat{y} = \text{Tr}(\hat{y} \hat{y}^T A)$$

$$\hat{v}^T \hat{P} \hat{v} = \text{Tr}(v^T P v) - \text{Tr}((\hat{x} - \bar{x})(\hat{x} - \bar{x})^T A^T P A)$$

$$= \text{Tr}(v^T v C^{-1}) - \text{Tr}((\hat{x} - \bar{x})(\hat{x} - \bar{x})^T C^{-1} x)$$

حال به طرفین تساوی اختیار است و دو اعمال می‌کنیم

$$\begin{aligned} E(\hat{v}^T \hat{P} \hat{v}) &= \zeta_0^2 E[\text{Tr}(v^T v C^{-1})] - \zeta_0^2 E[\text{Tr}((\hat{x} - \bar{x})(\hat{x} - \bar{x})^T C^{-1} x)] \\ &= \zeta_0^2 \text{Tr}[E(v^T v C^{-1})] - \zeta_0^2 \text{Tr}[E((\hat{x} - \bar{x})(\hat{x} - \bar{x})^T C^{-1} x)] \\ &= \zeta_0^2 (\text{Tr}(C^{-1} C^{-1}) - \text{Tr}(C^{-1} x C^{-1} x)) \\ &= \zeta_0^2 (\text{Tr}(I_n) - \text{Tr}(I_u)) \\ &= \zeta_0^2 (n - u) \end{aligned}$$

بنابراین نشان دادیم که:

$$E(\hat{v}^T \hat{P} \hat{v}) = \zeta_0^2 (n - u)$$

و با توجه به رابطه (۳۵) :

$$E(\zeta_0^2) = \frac{E(\hat{v}^T \hat{P} \hat{v})}{n - u} = \zeta_0^2$$

یا به عبارتی دیگر:

$$\zeta_0^2 = \frac{\hat{v}^T \hat{P} \hat{v}}{n - u}$$

... (۴۰)

یک برآورد کننده ناریب برای  $\hat{\sigma}_0^2$  است.

(n-u) همانگونه که قبلاً گفته شد درجه آزادی سرشکنی است

(در مدل پارامتریک  $df = n-u$ )

## ۲/۱۳- برآورد ماتریسهای کووریانس کمیتهای حاصل از سرشکنی مدل پارامتریک خطی

پس از برآورد  $\hat{\sigma}_0^2$  ماتریسهای کووریانس تیز از طریق  
برآورد کننده‌های ناریب دیل قابل برآورده است.

$$\underline{\underline{C}}_{\underline{x}} = \hat{\sigma}_0^2 (\underline{\underline{A}}^T \underline{\underline{P}} \underline{\underline{A}})^{-1} = \hat{\sigma}_0^2 (\underline{\underline{A}}^T \underline{\underline{Q}}^{-1} \underline{\underline{A}})^{-1} \quad \dots (41)$$

بطوری که :

$$E(\underline{\underline{C}}_{\underline{x}}) = \underline{\underline{C}}_{\underline{x}}$$

$$\underline{\underline{C}}_1 = \underline{\underline{A}} \underline{\underline{C}}_{\underline{x}} \underline{\underline{A}}^T = \hat{\sigma}_0^2 \underline{\underline{A}} (\underline{\underline{A}}^T \underline{\underline{Q}}^{-1} \underline{\underline{A}})^{-1} \underline{\underline{A}}^T \quad \dots (42)$$

بطوریکه :

$$E(\underline{\underline{C}}_1) = \underline{\underline{C}}_1$$

و بالاخره ،

$$\underline{\underline{C}}_v = \hat{\sigma}_0^2 (\underline{\underline{Q}} - \underline{\underline{A}} (\underline{\underline{A}}^T \underline{\underline{Q}}^{-1} \underline{\underline{A}})^{-1} \underline{\underline{A}}^T) \quad \dots (43)$$

نکته :

$$E(\hat{C}) = \hat{C}$$

$\underline{\underline{C}}$  ماتریس کوریانس مشاهدات است ، کمیتی که در سرشکنی معیار

$$\underline{\underline{P}} = \begin{pmatrix} 2 & \underline{\underline{C}}^{-1} \\ 0 & 1 \end{pmatrix} \quad \text{استخاب وزن قرار می‌کیرد :}$$

از طرفی دیگر بعد از سرشکنی می‌توان مشاهدات تصحیح شده

(مشاهداتی که در مدل  $\hat{\underline{\underline{A}}}\hat{\underline{x}} = \underline{\underline{1}}$  مصدق می‌کنند) را بدست آورد .

$$\hat{\underline{\underline{C}}} = \underline{\underline{A}}\hat{\underline{\underline{C}}}\hat{\underline{\underline{A}}}^T$$

دو تفاوت عمده بین  $\underline{\underline{C}}$  و  $\hat{\underline{\underline{C}}}$  وجود دارد ، اول آنکه  $\underline{\underline{C}}$

(حتی اگر  $\underline{\underline{C}}$  قطری استخاب شده باشد) دارای کوریانس (عنصر

خارج از قطر اصلی) مخالف صفر است . دوم آنکه  $\hat{\underline{\underline{C}}}$  مجرد است

(چون ماتریسی  $n \times n = \underline{\underline{n}}$  تعداد مشاهدات) و از مرتبه  $| \hat{\underline{\underline{C}}} | = 0$

تعداد مجموعات است . چون مرتبه  $\hat{\underline{\underline{A}}}$  و  $\hat{\underline{\underline{C}}}$  برابر  $u$  است

لذا  $\hat{\underline{\underline{C}}}$  نمی‌تواند معیار استخاب وزن قرار کیرد .

## ۲/۱۴- مدل پارامتریک غیر خطی

فرم کلی مدل دیاضی به صورت  $\underline{f}(\underline{x}, \underline{l}) = 0$  است . حالت خاصی از آن ، یعنی  $\underline{l} = \underline{f}(\underline{x})$  ، را مدل پارامتریک (غیر خطی) می‌نامیم (پارامتریک بدین خاطر آن که از حل این مدل مستقیماً به پارامترهای مجهول مرسیم و مشاهده به لحاظ صراحت آن نسبت به مشاهدات ) . این مدل در واقع دستگاهی است با تعداد معادلات (مشاهدات) بیش از مجهولات می‌باشد ، که به خاطر تعداد مشاهدات ، ناسازگار و بدون جواب است . اگر به این مدل مجهولات جدیدی به صورت زیر اضافه کنیم ،

$$\underline{v} + \underline{l} = \underline{f}(\underline{x}) \quad \dots (2)$$

این دستگاه به دستگاهی با بینهایت جواب تبدیل می‌گردد . حال از بین این بینهایت جواب ، جوابی وابسته می‌گزینیم که برای آن شرط زیر برقرار باشد .

$$w = \underline{v}^T P \underline{v} = \min. \quad \dots (3)$$

برای رسیدن به این جواب از  $w$  نسبت به  $\underline{x}$  مشتق گرفته مساوی صفر قرار می‌دهیم .

$$w = \underline{v}^T P \underline{v}$$

$$= (\underline{f}(\underline{x}) - \underline{l})^T P (\underline{f}(\underline{x}) - \underline{l}) \quad (\text{از تساوی } (2))$$

$$\frac{d w}{d \underline{x}} = \frac{d w}{d (\underline{f}(\underline{x}) - \underline{l})} \cdot \frac{d (\underline{f}(\underline{x}) - \underline{l})}{d \underline{x}}$$

$$= 2 (\underline{f}(\underline{x}) - \underline{l})^T P \frac{d (\underline{f}(\underline{x}))}{d \underline{x}} = 0$$

که در آن :

$$\frac{d(\underline{f(x)})}{dx} = \begin{bmatrix} \frac{d f_1(x)}{dx_1} & \frac{d f_1(x)}{dx_2} & \cdots & \frac{d f_1(x)}{dx_u} \\ \frac{d f_2(x)}{dx_1} & \frac{d f_2(x)}{dx_2} & \cdots & \frac{d f_2(x)}{dx_u} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{d f_n(x)}{dx_1} & \frac{d f_n(x)}{dx_2} & \cdots & \frac{d f_n(x)}{dx_u} \end{bmatrix} = \underline{A}$$

بنابر این خواهیم داشت :

$$2(\underline{f(x)} - \underline{1})^T \underline{P A} = 0$$

یا

$$\underline{f(x)}^T \underline{P A} - \underline{1}^T \underline{P A} = 0 \quad \dots (4)$$

دستگاه فوق یک دستگاه  $n$  معادله‌ای  $n$  مجهولی غیر خطی است . به این دستگاه به خاطر برابر تعداد معادلات با مجهولات دستگاه معادلات نرمال می‌گوییم . در ریاضیات هیچ روش تحلیلی کلی برای حل دستگاه‌های معادلات خطی وجود ندارد . اما حل عددی آنها با بسط معادلات حول مقادیر تقریبی مجهولات به سری تیلور ، صرف نظر کردن از جملات غیر خطی بسط ، ایجاد دستگاه معادلات خطی و تکرار بسط حول مقدار جدید بدست آمده برای مجهولات مسییر خواهد بود .

بنابر این چون می‌دانیم مدل پارامتریک غیر خطی نهایتاً به دستگاه معادلات نرمال غیر خطی خواهد رسید، مدل‌های غیر خطی را در ابتدا با بسط به سری تیلور و صرف نظر کردن از جملات بالاتر از مرتبه یک خطی می‌کنیم. به این ترتیب به معادلات نرمال خطی خواهیم رسید که از طریق روش‌های معمول حل دستگاه‌های معادلات معادلات خطی قابل حل است.

این عمل باعث می‌گردد که بتوان یک روش حل کلی برای مدل‌های پارامتریک خطی و غیر خطی بدست آورد.

اگر (۲) را حول  $\underline{x}^0$  به سری تیلور بسط دهیم و جملات غیر خطی را کنار بگذاریم، خواهیم داشت:

$$\underline{v} + \frac{1}{\underline{x}} = \underline{f}(\underline{x}^0) + \frac{d f}{d \underline{x}} (\underline{x} - \underline{x}^0) \quad \dots (5)$$

و با فرض

$$\left[ \begin{array}{l} \underline{x} - \underline{x}^0 = \underline{x} \\ \frac{1}{\underline{x}} - \frac{1}{\underline{x}^0} = \frac{1}{\underline{x}} \\ \frac{d f}{d \underline{x}} = A \end{array} \right]$$

به رابطه ذیل می‌رسیم،

$$\underline{v} + \frac{1}{\underline{x}} = A \underline{x} \quad \dots (6)$$

که دقیقاً مشابه رابطه (۲) است. بنابر دارای جواب کمترین مربخاتی مشابه (۷) است.

## ۲/۱۵ - نحوه تکرار و تعیین پارامترهای مجهول در مدل پارامتریک غیر خطی

در بخش قبل ملاحظه فرمودید که چگونه میتوان مدل پارامتریک غیر خطی را به فرمی مشابه معادلات پارامتریک خطی در آورد. که شاید در راه رسیدن به جواب کمترین برای آن به دستگاههای معادلات نرمال خطی خواهیم رسید که از طریق آنها مقادیر مجهولات تعیین خواهد شد. چون مقادیری که بسط حول آن صورت گرفته تقریبی بوده میتوان مقدار جدید مجهولات را به عنوان نقطه بسط جدید بکار برد و مجدداً مدل را خطی و به جواب کمترین مربعات آن رسید. این عمل میتواند آنقدر تکرار گردد تا جواب حاصل برای جزئیات این تکرار در شکل ذیل نشان داده شده است.

$$\begin{array}{c}
 \boxed{\begin{array}{l} \begin{matrix} & 0 \\ x & \hline - \end{matrix} \\ \downarrow \end{array}} \xleftarrow{} \\
 \boxed{\begin{array}{l} \frac{v}{-} + \frac{1}{-} = f(x) : \\ \frac{v}{-} + \frac{1}{-} = A \frac{x}{-} : \text{ به فرم} \end{array}} \\
 \downarrow \\
 \boxed{\hat{x} = (A^T P A)^{-1} A^T P \frac{1}{-}} \\
 \downarrow \\
 \boxed{\frac{\hat{x}}{-} = \frac{0}{-}} \xrightarrow{\text{خیر}} \boxed{\frac{1}{-} = \frac{0}{-} + \frac{\hat{x}}{-}} \\
 \mid \text{بلی} \\
 \boxed{\begin{array}{l} \hat{x} = \frac{\hat{x}^n}{-} + \frac{\hat{x}^{n-1}}{-} \\ \hat{v} = \frac{\hat{x}}{-} - \frac{1}{-} \\ \frac{1}{-} = \frac{1}{-} + \hat{v} \end{array}}
 \end{array}$$

در تکرار مرحله آخر  $\hat{l}$  را میتوان از وابطه خطی  $\hat{l} = Ax$  نیز بدست

آورد ، چون :

$$\begin{aligned}\hat{l} &= \frac{1}{v} + \hat{x} = \frac{1}{v} + A \underbrace{\frac{\hat{x}}{x} - \frac{1}{v}}_{\hat{x}} = \frac{1}{v} + A \underbrace{\frac{\hat{x}}{x} - \left( \frac{1-f(x)^{n-1}}{v} \right)}_{\frac{1}{v}} \\ &= A \frac{\hat{x}}{x} + \frac{f(x)^{n-1}}{v} = A \frac{\hat{x}}{x} + A \frac{x^{n-1}}{v} = A \left( \frac{\hat{x}}{x} + \frac{x^{n-1}}{v} \right) = A \frac{\hat{x}}{x} \dots (44)\end{aligned}$$

تمرین :

ماتریس کووریانس کمیتهای حاصل از سرشکنی مدل پارامتریک غیر خطی را بدست آوردید .

## ۱۶- سرشکنی معادلات شرط

قبل کفتیم که اگر تعداد معادلات بیشتر از مجهولات باشد ، درجه آزادی خواهیم داشت . در صورت وجود درجه آزادی ، به تعداد آن میتوان معادله به فرم :

$$g(\underline{l}) = 0 \dots (45)$$

بین مشاهدات ترتیب داد . به این معادلات که تعداد آنها برابر درجه آزادی است معادلات شرط کفته میشود (Condition Equations) . این معادلات معمولاً روابط هندسی موجود بین مشاهدات هستند ، که به خاطر خطای مشاهدات (تصادفی بودن مشاهدات) هیچگاه

برقرار نخواهد بود ( فرم خطی این معادلات به صورت  $\underline{C} = \underline{B} \underline{l} + \underline{B} \underline{v}$  قابل نمایش است ) .

با توجه به خطای اتفاقی مشاهدات به خود اجازه می دهیم که به مشاهدات تصحیحاتی کرده تا معادلات سازگار شوند . به این ترتیب (در فرم خطی) خواهیم داشت :

$$\underline{B} (\underline{l} + \underline{v}) = \underline{C} \quad \dots (46)$$

این تصحیحات مجھول آند و چون همیشه تعداد مشاهدات کمتر از درجه ع آزادی است دستگاه معادلات (46) بینهایت جواب خواهد داشت از بین بینهایت جواب موجود جوابی را اختحاب کنیم که علاوه بر معادلات (46) در شرط

$$\underline{v}^T \underline{P} \underline{v} = \min \quad \dots (47)$$

صدق کند که جوابی منحصر به فردی برای  $\underline{v}$  است (در صورت کمبود مرتبه نداشتند  $\underline{B}$ ) و به آن جواب کمترین مربعتات یا برآورد کمترین مربعتات اطلاق می کردد .

از معادله (46) داریم :

$$\underline{B} \underline{l} + \underline{B} \underline{v} = \underline{C} \quad \text{یا} \quad \underline{B} \underline{l} - \underline{C} + \underline{B} \underline{v} = \underline{0}$$

$\underline{w} = \underline{B} \underline{l} - \underline{C}$  را اختلاف بست (Misclousuer) می نامیم چون اگر معادلات خطایی نداشتند  $\underline{w}$  مساوی صفر می بود . بنابراین تفاوت آن از صفر را می توان خطای در بسته شدن تساوی دانست . بنابراین معادلات شرط بعد از اعمال تصحیحات مجعل بفرم زیر در خواهد آمد :

$$\underline{B} \underline{v} + \underline{w} = \underline{0} \quad \dots (48)$$

حال معادلات شرط غیر خطی را در نظر می‌کیریم . با بسط به سری تیلور این معادلات حول  $\underline{1}$  (مقادیر مشاهدات) داریم :

$$\underline{g}(\underline{1}) + \frac{\underline{g}}{\underline{1}} (\underline{1} - \underline{1}) = \underline{0}$$

$\underline{w}$        $\underline{B}$        $\underline{v}$

که آن را می‌توان به فرم ذیر نوشت:

$$\underline{B} \underline{v} - \underline{w} = \underline{0}$$

ملاحظه می‌گردد که در اینگونه مدلها نیز پس از خطی کردن به فرم  $\underline{B} \underline{v} + \underline{w} = \underline{0}$  خواهیم رسید . پس بقیه مراحل برای مدلهای خطی و غیر خطی یکسان خواهد بود . برای بدست آوردن جوابی که هم در شرط (۴۷) صدق کند و هم در معادله (۴۸) از روش لاگرانژ استفاده می‌کنیم .

$$\underline{\phi} = \underline{v}^T \underline{P} \underline{v} + 2 \underline{k}^T (\underline{B} \underline{v} + \underline{w}) \\ = 0$$

$$\left[ \begin{array}{l} \frac{\partial \underline{\phi}}{\partial \underline{v}} = 2 \underline{v}^T \underline{P} + 2 \underline{k}^T \underline{B} = \underline{0} \\ \frac{\partial \underline{\phi}}{\partial \underline{k}} = 2 (\underline{B} \underline{v} + \underline{w})^T = \underline{0} \end{array} \right] \dots (49)$$

$$\left[ \begin{array}{l} \frac{\partial \underline{\phi}}{\partial \underline{v}} = 2 \underline{v}^T \underline{P} + 2 \underline{k}^T \underline{B} = \underline{0} \\ \frac{\partial \underline{\phi}}{\partial \underline{k}} = 2 (\underline{B} \underline{v} + \underline{w})^T = \underline{0} \end{array} \right] \dots (50)$$

دستگاه فوق دستگاه معادلات نرمال است که از حل آن به  $\underline{v}$  و  $\underline{k}$  دست خواهیم یافت .

با توجه به (۴۹) :

$$\underline{P} \underline{v} = - \underline{B}^T \underline{k}$$

$$\Rightarrow \hat{\underline{v}} = - \underline{\underline{P}}^{-1} \underline{\underline{B}}^T \underline{k} \quad \dots (51)$$

و با توجه به (۵۰) و (۵۱)

$$- \underline{\underline{B}} \underline{\underline{P}}^{-1} \underline{\underline{B}}^T \hat{\underline{k}} + \underline{w} = 0$$

یا

$$(\underline{\underline{B}} \underline{\underline{P}}^{-1} \underline{\underline{B}}^T) \hat{\underline{k}} = \underline{w}$$

در صورت غیر مجرد بودن ( $\underline{\underline{B}} \underline{\underline{P}}^{-1} \underline{\underline{B}}^T$ )

$$\hat{\underline{k}} = (\underline{\underline{B}} \underline{\underline{P}}^{-1} \underline{\underline{B}}^T)^{-1} \underline{w} \quad \dots (52)$$

و بالاخره با استفاده از (۵۱) و (۵۲)

$$\hat{\underline{v}} = - \underline{\underline{P}}^{-1} \underline{\underline{B}} (\underline{\underline{B}} \underline{\underline{P}}^{-1} \underline{\underline{B}}^T)^{-1} \underline{w} \quad \dots (53)$$

توجه:  $\hat{\underline{v}}$  و  $\hat{\underline{k}}$  مقادیر خاصی از  $\underline{v}$  و  $\underline{k}$  هستند که در شرط (۴۷) و معادلات (۴۸) صدق می‌کنند.

نکته: در اینجا نیز اگر بجای  $\underline{\underline{P}}^{-1}$  به  $\underline{\underline{Q}}_{-1}$  استفاده شود نتیجه برآورد یکسان خواهد بود.

برای اینکه نشان دهیم این جواب معتبر نیم کننده است از رابطه

(۴۹) نسبت به  $\underline{v}$  مجددا مشتق می‌کنیم:

$$\frac{\delta^2 \phi}{\delta \underline{v}^2} = 2 \underline{\underline{P}} \quad \dots (54)$$

بنابراین در صورتیکه  $\underline{\underline{P}}$  را اکیدا مشتبث انتخاب کرده باشیم شرط

(۴۷) به ازاء مقادیر برآورده شده برقرار خواهد بود .

## ۲/۱۷- جواب حاصل از سرشکنی معادلات شرط

و

### شبه معکوس

در بخش قبل دیدیم که مدل :

$$\underline{B} \underline{v} + \underline{w} = \underline{0}$$

دستگاهی با تعداد مجهولات ( $\underline{v}$ ) بیشتر از معادلات است و با شرط کمترین مربuat یعنی:

به جواب منحصر به فرد زیر رسیدیم :

$$\hat{\underline{v}} = -\underline{P}^{-1} \underline{B}^T (\underline{B} \underline{P}^{-1} \underline{B}^T)^{-1} \underline{w}$$

یا

$$\hat{\underline{v}} = \underline{H} \underline{w}$$

یعنی  $\underline{H}$  را میتوانیم نوعی معکوس برای  $\underline{B}$  داشت . از طرفی دیگر میدانیم که برای هر ماتریس دلخواه مانند  $\underline{B}$  ماتریسی مانند  $\underline{H}$  با خواص ذیل وجود دارد .

$$(i) \quad \underline{B} \underline{H} \underline{B} = \underline{B}$$

( اگر  $\underline{H}$  تنها دارای این خاصیت باشد معکوس فراکیر (Generalized Inverse) نامیده میشود . برای هر ماتریس بینهایت معکوس فراکیر میتوان یافت . اگر  $\underline{H}$  علاوه بر شرط (i) در شروط ذیل نیز صدق کند شبه معکوس (Pseudo Inverse) نامیده میشود .

$$(ii) \quad \underline{H} \underline{B} \underline{H} = \underline{H} \underline{B}$$

$$(iii) \quad (\underline{H} \ \underline{B})^T = \underline{H} \ \underline{B}$$

$$(iv) \quad (\underline{B} \ \underline{H})^T = \underline{B} \ \underline{H}$$

شبه معکوی بر خلاف معکوس فراگیر منحصر به فرد است. حال این فکر به ذهن متبدل می‌گردد که چه ارتباطی بین  $\underline{H}$  حاصل از روش کمترین مربعات و شبه معکوس  $\underline{B}$  وجود دارد. در نظر داشته باشید که هر دو منحصر به فرد هستند. بنابر این بد نیست که چهار خاصیت فوق را برای ماتریس  $\underline{H}$  حاصل از روش کمترین مربعات بررسی کنیم. شرط (i) ، (ii) و (iv) به وضوح صادقاند. اما در مورد شرط سوم داریم:

$$\begin{aligned} (iii) \quad (\underline{H} \ \underline{B})^T &= (\underline{P} \ \underline{B}^T \ \underline{B} \ \underline{P}^T \ \underline{B}^T)^T \\ &= \underline{B}^T (\underline{B} \ \underline{P}^T \ \underline{B}^T)^{-1} \underline{B} \ \underline{P}^T \end{aligned}$$

این شرط تنها در صورتی برقرار خواهد بود که  $\underline{P} = \underline{I}$  باشد.

بنابر این در صورتیکه  $\underline{I} = \underline{P}$  شبه معکوس  $\underline{B}$  خواهد بود

$$\cdot \quad \underline{H} = \underline{B}^+$$

از طرف دیگر  $\underline{H}$  دارای خصوصیت جالب دیگری است:

$$\underline{B} \ \underline{H} = \underline{I}$$

یعنی اگر  $\underline{H}$  دا از سمت راست در  $\underline{B}$  ضرب کنیم به ماتریس یکه خواهیم رسید، به این خاطر به  $\underline{H}$  (Left Orthogonal Inverse) کفته می‌شود. (علت بکار بردن لفظ Orthogonal بعداً روشن می‌شود).

## ۲/۱۸ - ماتریس‌های کووریانس کمیتهای برآورده شده از طریق سرشکنی مدل شرط

### ۱- ماتریس کووریانس اختلاف بست ( $\underline{\underline{w}}$ )

بردار اختلاف بست در حالت کلی بدین صورت بدست می‌آید:

$$\underline{\underline{w}} = \frac{\underline{\underline{f}}(1)}{-0}$$

در این رابطه  $\frac{1}{-0}$  بردار مشاهدات و متغیر تصادفی است، بنابراین طبق قانون انتشار خطاهای داریم:

$$\begin{aligned} \underline{\underline{C}}_{\underline{\underline{w}}} &= \frac{\frac{\partial \underline{\underline{f}}}{\partial \underline{\underline{l}}}}{\frac{\partial \underline{\underline{l}}}{\partial \underline{\underline{l}}_0}} \underline{\underline{C}}_{\underline{\underline{l}}_0} \left( \frac{\frac{\partial \underline{\underline{f}}}{\partial \underline{\underline{l}}}}{\frac{\partial \underline{\underline{l}}}{\partial \underline{\underline{l}}_0}} \right)^T \\ &= \underline{\underline{B}} \underline{\underline{C}}_{\underline{\underline{l}}} \underline{\underline{B}}^T \end{aligned} \quad \dots (55)$$

### ۲- ماتریس کووریانس تصحیحات برآورده شده ( $\hat{\underline{\underline{v}}}$ )

$$\begin{aligned} \hat{\underline{\underline{v}}} &= -\underline{\underline{P}}^{-1} \underline{\underline{B}}^T (\underline{\underline{B}} \underline{\underline{P}}^{-1} \underline{\underline{B}}^T)^{-1} \underline{\underline{w}} \\ \hat{\underline{\underline{C}}}_{\hat{\underline{\underline{v}}}} &= \underline{\underline{P}}^{-1} \underline{\underline{B}}^T \underbrace{(\underline{\underline{B}} \underline{\underline{P}}^{-1} \underline{\underline{B}}^T)^{-1} \underline{\underline{C}}_{\underline{\underline{l}}} (\underline{\underline{B}} \underline{\underline{P}}^{-1} \underline{\underline{B}}^T)^{-1} \underline{\underline{B}} \underline{\underline{P}}^{-1}}_{\underline{\underline{I}}} \\ &= \underline{\underline{P}}_0^{-1} \underline{\underline{B}}^T (\underline{\underline{B}} \underline{\underline{P}}^{-1} \underline{\underline{B}}^T)^{-1} \underline{\underline{B}} \underline{\underline{P}}^{-1} \\ &= \underline{\underline{C}}_{\underline{\underline{l}}} \underline{\underline{B}}^T (\underline{\underline{B}} \underline{\underline{C}}_{\underline{\underline{l}}} \underline{\underline{B}}^T)^{-1} \underline{\underline{B}} \underline{\underline{C}}_{\underline{\underline{l}}} \quad (\underline{\underline{P}} = \underline{\underline{\sigma}}_0^2 \underline{\underline{C}}_{\underline{\underline{l}}}^{-1}) \Rightarrow \underline{\underline{P}}^{-1} = \frac{\underline{\underline{C}}_{\underline{\underline{l}}}}{\underline{\underline{\sigma}}_0^2} \\ &\dots (56) \end{aligned}$$

## ماتریس کووریانس مشاهدات برآورد شده ( $\hat{L}$ )

$$\begin{aligned}
 \hat{L} &= \underline{L} + \hat{\underline{v}} \\
 &= \underline{L} - \underline{P}^{-1} \underline{B}^T (\underline{B} \underline{P}^{-1} \underline{B}^T)^{-1} \underline{w} \\
 &= \underline{L} - \underline{P}^{-1} \underline{B}^T (\underline{B} \underline{P}^{-1} \underline{B}^T)^{-1} f(\underline{l}) \\
 \underline{C}_{\hat{L}} &= (\underline{I} - \underline{P}^{-1} \underline{B}^T (\underline{B} \underline{P}^{-1} \underline{B}^T)^{-1} \underline{B}) \underline{C}_{\underline{l}} (\underline{I} - \underline{B}^T (\underline{B} \underline{P}^{-1} \underline{B}^T)^{-1} \underline{B} \underline{P}^{-1}) \\
 &= \underline{C}_{\underline{l}} - \underline{C}_{\underline{l}} \underline{B}^T (\underline{B} \underline{P}^{-1} \underline{B}^T)^{-1} \underline{B} \underline{P}^{-1} - \underline{P}^{-1} \underline{B}^T (\underline{B} \underline{P}^{-1} \underline{B}^T)^{-1} \underline{B} \underline{C}_{\underline{l}} \\
 &\quad + \underline{P}^{-1} \underline{B}^T (\underline{B} \underline{P}^{-1} \underline{B}^T)^{-1} \underline{B} \underline{C}_{\underline{l}} \underline{B}^T (\underline{B} \underline{P}^{-1} \underline{B}^T)^{-1} \underline{B} \underline{P}^{-1} \\
 &= \underline{C}_{\underline{l}} - \underline{C}_{\underline{l}} \underline{B}^T (\underline{B} \underline{C}_{\underline{l}} \underline{B}^T)^{-1} \underline{B} \underline{C}_{\underline{l}} = \underline{C}_{\underline{l}} - \underline{C}_{\underline{v}} \quad \dots \quad (57)
 \end{aligned}$$

نکته: با توجه به جواب کمترین مرباعات حاصل برای  $\hat{\underline{v}}$ :

$$\hat{\underline{v}} = - \underline{P}^{-1} \underline{B}^T (\underline{B} \underline{P}^{-1} \underline{B}^T)^{-1} \underline{w}$$

ملاحظه می‌گردد که حتی اگر ماتریس وزن را مساوی معکوس ماتریس کووریانس نسبی قرار دهیم نتیجه حاصل همان خواهد بود که در صورت انتخاب وزن بصورت عکس ماتریس کووریانس حاصل می‌شود. اما در مورد ماتریسمای کووریانسی حاصل وضع چنین نیست و تمامی آنها در صورتی قابل محاسبه خواهند بود که ماتریس کووریانس مشاهدات در دست بیاشد که معمولاً چنین نیست. بدین خاطر سراغ برآورد کننده‌های ناریب آنها یعنی:

$$\hat{\underline{C}}_v = \hat{\sigma}_0^2 \underline{B}^T (\underline{B} \underline{Q} \underline{B}^T)^{-1} \quad \dots (58)$$

$$\hat{\underline{C}}_1 = \hat{\sigma}_0^2 (\underline{Q} - \underline{Q} \underline{B}^T (\underline{B} \underline{Q} \underline{B}^T)^{-1} \underline{B} \underline{Q}) \quad \dots (59)$$

$$\hat{\underline{C}}_w = \hat{\sigma}_0^2 \underline{B} \underline{Q} \underline{B}^T \quad \dots (60)$$

خواهیم رفت.

تمرین: ثابت کنید کمیتهای فوق الذکر برآورد کنندۀ های

ناریبی برای  $\hat{\underline{C}}_1$  و  $\hat{\underline{C}}_v$  هستند.

نکته:

معادله شرط غیر خطی به فرم  $f(1) = 0$  است که با بسط آن به سوی تیلور حول مشاهدات و صرف نظر کردن از جملات غیر خطی به فرم مقابله تبدیل می‌کنیم:

$$\underline{B} \underline{v} + \underline{w} = 0$$

نکته مهم در این بسط آن است که  $\underline{1}$  و  $\underline{1}$  بسیار بهم نزدیک خواهند بود در نتیجه تقریب خطی تقریبی بسیار خوب از مدل در همسایگی  $\underline{1}$  است ولذا نیازی به تکرار نیست و از مدل خطی شده می‌توان به جواب رسید.

## ۲/۱۹ - تبدیل مشاهدات با وزن $P$ به مشاهدات با وزن یکه (I)

در بخش (۱/۱۸) ذکر شد که سریعترین و دقیقترین روش یافتن معکوس ماتریس‌های اکیدا مثبت و متقاضی ووش تجزیه چولسکی است. از طرفی دیگر در بخش‌های قبلی این فصل ملاحظه کردید که ماتریس ضرایب معادلات نرمال، ماتریسی اکیدا مثبت و متقاضی است. بنابراین بهترین روش برای محاسبه معکوس آن روش Choleski است. بعلاوه از این روش می‌توان در تبدیل مشاهدات با وزن  $P$  به مشاهدات با وزن یکه استفاده کرد.

ثابت خواهیم کرد که اگر  $\underline{\underline{L}}^T \underline{\underline{L}}$  دارای وزن  $P$  باشد شابت خواهیم کرد که اگر  $\underline{\underline{L}}^T \underline{\underline{L}}$  دارای وزن یکه (I) است  $\underline{\underline{L}}^T \underline{\underline{P}} = \underline{\underline{L}} \underline{\underline{L}}^T$  و  $\underline{\underline{L}}^T \underline{\underline{P}} = \underline{\underline{L}} \underline{\underline{L}}^T$  یعنی  $\underline{\underline{B}}^T \underline{\underline{B}}^{-1} \underline{\underline{B}}^T \underline{\underline{L}}^*$  که  $\underline{\underline{B}}^T \underline{\underline{B}}^{-1}$  از معادله مشاهده اصلی ( $\underline{\underline{L}}^T \underline{\underline{A}} \underline{\underline{x}} = \underline{\underline{L}}^T \underline{\underline{P}}$ ) با ضرب طرفین از چپ در  $\underline{\underline{L}}^T$  حاصل شده است:

$$\begin{array}{c} \underline{\underline{L}}^T \underline{\underline{L}}^* \\ \hline \underline{\underline{L}}^T \underline{\underline{A}} \underline{\underline{x}} \end{array}$$

$$\underline{\underline{L}}^T \underline{\underline{L}}^* = \underline{\underline{B}}^T \underline{\underline{B}}^{-1} \underline{\underline{B}}^T \underline{\underline{L}}^*$$

$$\Rightarrow \underline{\underline{x}}^* = (\underline{\underline{B}}^T \underline{\underline{B}}^{-1})^{-1} \underline{\underline{B}}^T \underline{\underline{L}}^* = (\underline{\underline{A}}^T \underline{\underline{L}} \underline{\underline{L}}^T \underline{\underline{A}})^{-1} \underline{\underline{A}}^T \underline{\underline{L}} \underline{\underline{L}}^T \underline{\underline{L}}^* = (\underline{\underline{A}}^T \underline{\underline{P}} \underline{\underline{A}})^{-1} \underline{\underline{A}}^T \underline{\underline{P}} \underline{\underline{L}}^*$$

مَنَابِع

- 1, Cooper, M. A. R. Fundamentals of Survey Measurements  
and analysis (1974), Collins Technical Books.
- 2, Cooper, M. A. R. Control Surveys In Civil Engineering.
- 3, Vanicek, P. and Krakiwisky, E. Geodesy (1986), North  
Holland.
- 4, Mikhail, E. M. Observations and Least Squares (1976),  
IEP— A Dun-Donnelley Publisher, New York.
- 5, Krakiwisky, E. Papers For the CISM Adjustment and  
Analysis Seminars, (1987), The Canadian  
Institute of Surveying and Mapping, Ottawa,  
Canada.