



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ
Εργαστήριο Θερμικών Στροβιλομηχανών
Μονάδα Παράλληλης Υπολογιστικής Ρευστοδυναμικής &
Βελτιστοποίησης

ΜΕΘΟΔΟΙ ΑΕΡΟΔΥΝΑΜΙΚΗΣ ΒΕΛΤΙΣΤΟΠΟΙΗΣΗΣ

(7^ο Εξάμηνο Σχολής Μηχ.Μηχ. ΕΜΠ)

ΑΙΤΙΟΚΡΑΤΙΚΗ ΒΕΛΤΙΣΤΟΠΟΙΗΣΗ

Κυριάκος Χ. Γιαννάκογλου

Καθηγητής ΕΜΠ

kgianna@central.ntua.gr

<http://velos0.ltt.mech.ntua.gr/research/>



Γιατί ασχολούμαστε με τετραγωνικές μορφές;

Ορισμός 3.1 Ορίζουμε ως *τετραγωνική μορφή* (quadratic form) ενός διανύσματος \vec{x} κάθε βαθμωτή συνάρτηση της μορφής

$$F(\vec{x}) = \frac{1}{2} \vec{x}^T A \vec{x} - \vec{b}^T \vec{x} + c \quad (3.7)$$

όπου A ένα τετραγωνικό μητρώο και c μια βαθμωτή σταθερά.

Θεώρημα 3.1 Αν το A είναι συμμετρικό και θετικά ορισμένο μητρώο, τότε το ελάχιστο της $F(\vec{x})$ (σχέση 3.7) ταυτίζεται με τη λύση του γραμμικού συστήματος

$$A \vec{x} = \vec{b}$$

όπου A ένα τετραγωνικό μητρώο και c μια βαθμωτή σταθερά.

$$\nabla F(\vec{x}) = \frac{1}{2} A^T \vec{x} + \frac{1}{2} A \vec{x} - \vec{b}$$


$$\nabla F(\vec{x}) = A \vec{x} - \vec{b}$$



Γιατί ασχολούμαστε με τετραγωνικές μορφές;

$$\begin{aligned} F(\vec{x}^* + \vec{e}) &= \frac{1}{2}(\vec{x}^* + \vec{e})^T A(\vec{x}^* + \vec{e}) - \vec{b}^T(\vec{x}^* + \vec{e}) + c \\ &= \frac{1}{2}\vec{x}^{*T} A \vec{x}^* + \vec{e}^T A \vec{x}^* + \frac{1}{2}\vec{e}^T A \vec{e} - \vec{b}^T \vec{x}^* - \vec{b}^T \vec{e} + c \\ &= \frac{1}{2}\vec{x}^{*T} A \vec{x}^* - \vec{b}^T \vec{x}^* + c + \vec{e}^T \vec{b} + \frac{1}{2}\vec{e}^T A \vec{e} - \vec{b}^T \vec{e} \\ &= F(\vec{x}^*) + \frac{1}{2}\vec{e}^T A \vec{e} \end{aligned}$$

Γραφική παράσταση τετραγωνικής Συνάρτησης





Απότομη Κάθοδος για Γραμμικά Προβλήματα

Μέθ. Απότομης Καθόδου

$$\begin{aligned}\vec{x}^{n+1} &= \vec{x}^n + \eta \vec{p}^n \\ \vec{p}^n &= -\nabla F(\vec{x}^n)\end{aligned}$$

Για την ελαχιστοποίηση της

$$F(\vec{x}) = \frac{1}{2} \vec{x}^T A \vec{x} - \vec{b}^T \vec{x} + c$$

Είναι ως να λύνεται η

$$A \vec{x} = \vec{b}$$

Με υπόλοιπο της εξίσωσης το

$$\vec{r}^n = \vec{b} - A \vec{x}^n$$

Άρα θα είναι

$$\vec{r}^n = \vec{p}^n = -\nabla F(\vec{x}^n) = \vec{b} - A \vec{x}^n$$

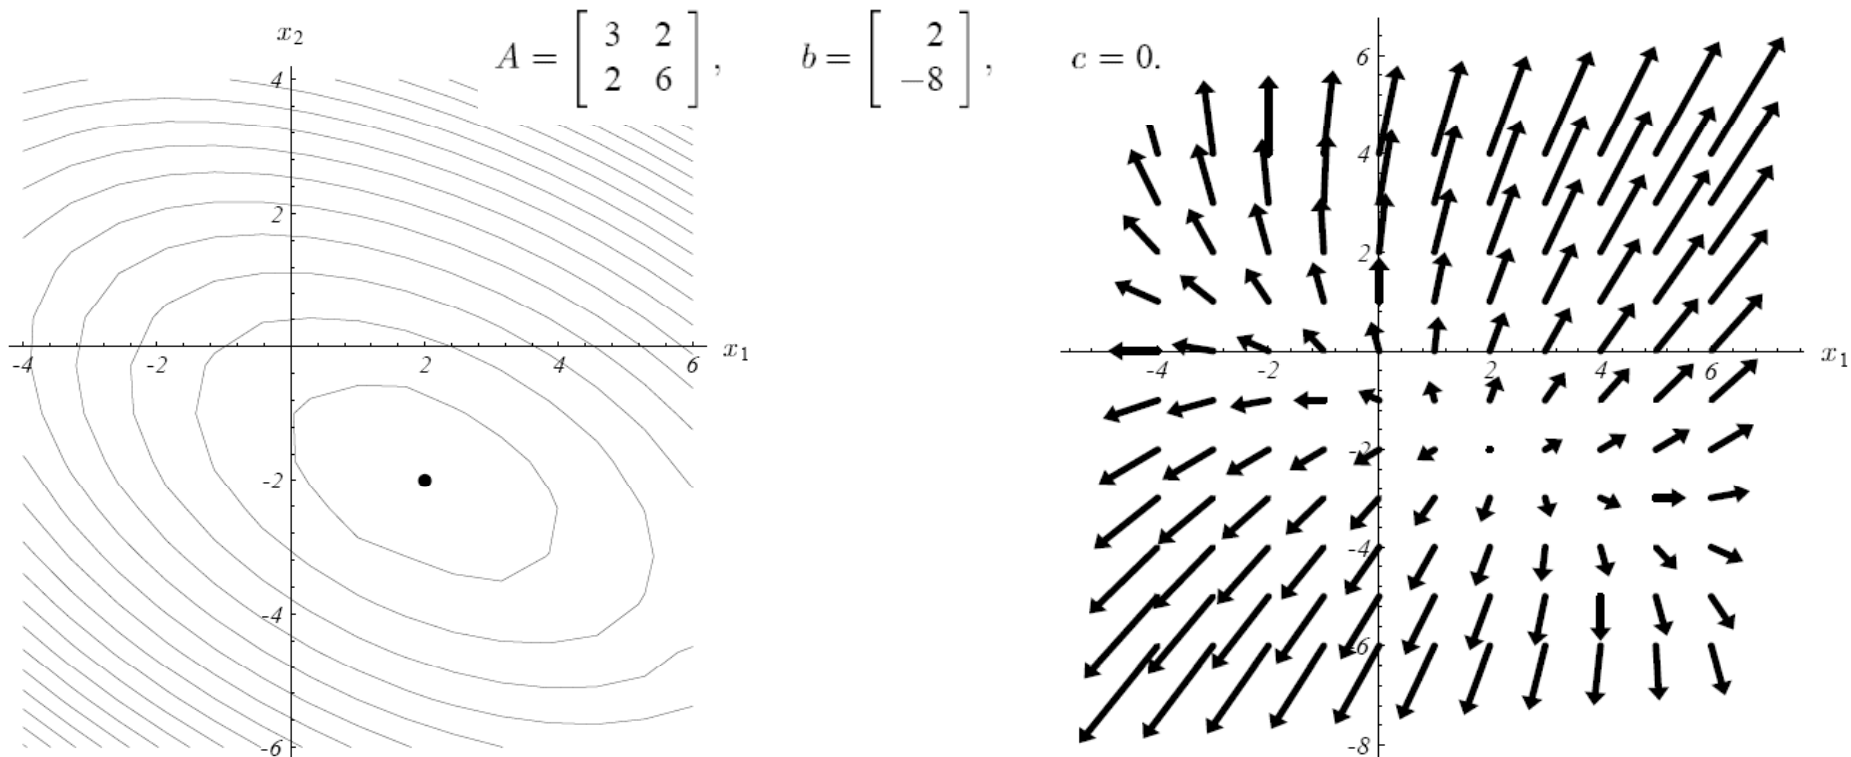
$$\vec{x}^{n+1} = \vec{x}^n + \eta^n \vec{r}^n$$

Απότομη Κάθοδος για Γραμμικά Προβλήματα

Ποιο το βέλτιστο βήμα η ;
$$\frac{d}{d\eta} F(\vec{x}^{n+1}) = \nabla F(\vec{x}^{n+1})^T \frac{d}{d\eta} \vec{x}^{n+1} = 0$$

ή
$$\nabla F(\vec{x}^{n+1})^T \vec{r}^n = -\vec{r}^{n+1}{}^T \vec{r}^n = 0$$


Κατανόηση του τρόπου που προχωρά η Απότομη Κάθοδος:



Απότομη Κάθοδος για Γραμμικά Προβλήματα



Έστω ότι ξεκινώ από το $(-2, -2)$:



Παράδειγμα από το:

An Introduction to
the Conjugate Gradient Method
Without the Agonizing Pain

Edition $1\frac{1}{4}$


Jonathan Richard Shewchuk

August 4, 1994



Απότομη Κάθοδος για Γραμμικά Προβλήματα

Έστω ότι ξεκινώ από το $(-2,-2)$. Πως καταλήγω στο $(2,-2)$:





Απότομη Κάθοδος για Γραμμικά Προβλήματα

Υπολογισμός του (βέλτιστου) βήματος η :

$$\begin{aligned}\vec{r}^{n+1T} \vec{r}^n &= 0 \\ (\vec{b} - A\vec{x}^{n+1})^T \vec{r}^n &= 0 \\ (\vec{b} - A(\vec{x}^n + \eta^n \vec{r}^n))^T \vec{r}^n &= 0 \\ (\vec{b} - A\vec{x}^n)^T \vec{r}^n - \eta^n (A\vec{r}^n)^T \vec{r}^n &= 0 \\ (\vec{b} - A\vec{x}^n)^T \vec{r}^n &= \eta^n (A\vec{r}^n)^T \vec{r}^n \\ \vec{r}^{nT} \vec{r}^n &= \eta^n \vec{r}^{nT} A \vec{r}^n\end{aligned}$$

Άρα, τελικός τύπος για το η :

$$\eta^n = \frac{\vec{r}^{nT} \vec{r}^n}{\vec{r}^{nT} A \vec{r}^n}$$



Απότομη Κάθοδος για Γραμμικά Προβλήματα

Αλγόριθμος:

Βήμα 0: Επιλογή αρχικής λύσης \vec{x}^0 . Δείκτης $n = 0$.

Βήμα 1: Υπολογισμός υπολοίπου $\vec{r}^n = \vec{b} - A\vec{x}^n$.

Βήμα 2: Υπολογισμός μεγέθους βήματος $\eta^n = \frac{\vec{r}^{nT}\vec{r}^n}{\vec{r}^{nT}A\vec{r}^n}$,

Βήμα 3: Ανανέωση λύσης $\vec{x}^{n+1} = \vec{x}^n + \eta^n \vec{r}^n$.

Βήμα 4: Ανανέωση τιμής δείκτη $n \leftarrow n+1$. Επιστροφή στο βήμα 1, μέχρι σύγκλισης.

Σχόλια περί υπολογιστικού κόστους ...

“matrix-vector products”

Οικονομία:

$$\begin{aligned}\vec{x}^{n+1} &= \vec{x}^n + \eta^n \vec{r}^n \\ \vec{b} - A\vec{x}^{n+1} &= \vec{b} - A\vec{x}^n - \eta^n A\vec{r}^n \\ \vec{r}^{n+1} &= \vec{r}^n - \eta^n A\vec{r}^n\end{aligned}$$



Απότομη Κάθοδος για Γραμμικά Προβλήματα

Νέος Αλγόριθμος:

Βήμα 0: Επιλογή αρχικής λύσης \vec{x}^0 . Δείκτης $n = 0$. Υπολογισμός αρχικού υπολοίπου $\vec{r}^n = \vec{b} - A\vec{x}^n$.

Βήμα 1: Υπολογισμός μεγέθους βήματος $\eta^n = \frac{\vec{r}^{nT}\vec{r}^n}{\vec{r}^{nT}A\vec{r}^n}$, με αποθήκευση του διάνυσματος $A\vec{r}^n$ για επόμενη χρήση.

Βήμα 2: Ανανέωση λύσης $\vec{x}^{n+1} = \vec{x}^n + \eta^n \vec{r}^n$.

Βήμα 3: Ανανέωση υπολοίπου $\vec{r}^{n+1} = \vec{r}^n - \eta^n A\vec{r}^n$, χρησιμοποιώντας το ήδη υπολογισμένο διάνυσμα $A\vec{r}^n$. Ανανέωση τιμής δείκτη $n \leftarrow n + 1$ και επιστροφή στο βήμα 1, μέχρι σύγκλισης.

Τι πρόβλημα/μειονέκτημα έχει αυτός;



Η Έννοια της Συζυγίας

Είναι η αφετηρία για τη θεμελίωση της **Μεθόδου των Συζυγών Κατευθύνσεων!**

Ιδέα: Να μην ξαναχρησιμοποιείται κατεύθυνση που ήδη σαρώθηκε!

Ορισμός κατευθύνσεων (το πολύ N) $\vec{p}^0, \vec{p}^1, \vec{p}^2, \dots, \vec{p}^{N-1}$

τέτοιων ώστε:

$$\vec{p}^{iT} \vec{p}^j = 0, \quad i \neq j$$

Στο γραμμικό πρόβλημα, με την απότομη κάθοδο, το σφάλμα (error):

$$\vec{e}^{n+1} = \vec{e}^n + \eta^n \vec{p}^n$$

Απαιτήση:

$$\vec{p}^{nT} \vec{e}^{n+1} = 0$$

Ή

$$\vec{p}^{nT} \vec{e}^n + \eta^n \vec{p}^{nT} \vec{p}^n = 0$$

$$\eta^n = - \frac{\vec{p}^{nT} \vec{e}^n}{\vec{p}^{nT} \vec{p}^n} \leftarrow \text{Κι αυτό;;;}$$

Άρα:



Συζυγία ή A-ορθογώνια διανύσματα:

δηλαδή απαιτώ:
$$\vec{p}^{iT} A \vec{p}^j = 0, \quad i \neq j$$

Ισχύει:

$$\begin{aligned} \frac{dF(\vec{x}^{n+1})}{d\eta^n} &= 0 \\ \nabla F(\vec{x}^{n+1}) \frac{d\vec{x}^{n+1}}{d\eta^n} &= 0 \\ -\vec{r}^{n+1T} \vec{p}^n &= 0 \end{aligned}$$

Όμως:

$$\begin{aligned} \vec{r}^{n+1} &= \vec{b} - A\vec{x}^{n+1} = \vec{b} - A(\vec{x}^* + \vec{e}^{n+1}) \\ \vec{r}^{n+1} &= -A\vec{e}^{n+1} \end{aligned}$$

Άρα:

$$\vec{p}^{nT} A \vec{e}^{n+1} = 0$$

Μέθοδος Συζυγών Κατευθύνσεων (Conjugate Directions)



Με τη νέα απαίτηση, το βέλτιστο βήμα η είναι:

$$\begin{aligned}\vec{p}^{nT} A \vec{e}^{n+1} &= 0 \\ \vec{p}^{nT} A (\vec{e}^n + \eta^n \vec{p}^n) &= 0 \\ \vec{p}^{nT} A \vec{e}^n + \eta^n \vec{p}^{nT} A \vec{p}^n &= 0 \\ -\vec{p}^{nT} \vec{r}^n + \eta^n \vec{p}^{nT} A \vec{p}^n &= 0\end{aligned}$$

Άρα, νέα χρήσιμη έκφραση η :

$$\eta^n = \frac{\vec{p}^{nT} \vec{r}^n}{\vec{p}^{nT} A \vec{p}^n}$$

Μια τέτοια μέθοδος συγκλίνει **το πολύ σε N βήματα**. Η απόδειξη υπάρχει στο βιβλίο, αλλά μπορείτε εύκολα να την καταλάβετε με βάση την ιδέα που εφαρμόστηκε.

Τι δεν είπαμε: Πως θα βρεθούν τα $\vec{p}^0, \vec{p}^1, \vec{p}^2, \dots, \vec{p}^{N-1}$



Συζυγής Διαδικασία των Gram-Schmidt

$$\vec{p}^n = \vec{u}^n + \sum_{i=0}^{n-1} \beta_{ni} \vec{p}^i$$

όπου $\vec{u}^0, \vec{u}^1, \vec{u}^2, \dots, \vec{u}^{N-1}$ είναι N γραμμικά ανεξάρτητα διανύσματα.

Λ.χ. οι συντελεστές για $N=4$:

$$\begin{bmatrix} - & - & - & - \\ \beta_{10} & - & - & - \\ \beta_{20} & \beta_{21} & - & - \\ \beta_{30} & \beta_{31} & \beta_{32} & - \end{bmatrix}$$

Απαιτήση για Α-ορθογωνιότητα:

$$\left. \begin{aligned} \vec{p}^{iT} A \vec{p}^j &= 0 \\ (\vec{u}^i + \sum_{m=0}^{i-1} \beta_{im} \vec{p}^m)^T A \vec{p}^j &= 0 \\ \vec{u}^{iT} A \vec{p}^j + \sum_{m=0}^{i-1} \beta_{im} \vec{p}^{mT} A \vec{p}^j &= 0 \\ \vec{u}^{iT} A \vec{p}^j + \beta_{ij} \vec{p}^{jT} A \vec{p}^j &= 0 \end{aligned} \right\} \beta_{ij} = - \frac{\vec{u}^{iT} A \vec{p}^j}{\vec{p}^{jT} A \vec{p}^j}, \quad i > j$$



Μέθοδος Συζυγών Κλίσεων (Conjugate Gradient, CG)

Χρησιμοποιεί τα υπόλοιπα \vec{r}^i στη θέση των u^i στην προηγούμενη μέθοδο. Άρα:

$$\beta_{ij} = -\frac{\vec{r}^i T A \vec{p}^j}{\vec{p}^j T A \vec{p}^j}, \quad i > j$$

Στη Gram-Schmidt μπορεί ναδειχτεί (βλ. βιβλίο) ότι:

$$\vec{r}^{n+1} = \vec{r}^n - \eta^n A \vec{p}^n$$

Άρα:

$$\eta^j \vec{r}^i T A \vec{p}^j = \vec{r}^i T \vec{r}^j - \vec{r}^i T \vec{r}^{j+1}$$

Καταλήγουμε ότι:

$$\vec{r}^i T A \vec{p}^j = \begin{cases} \frac{1}{\eta^j} \vec{r}^j T \vec{r}^j & , i = j \\ -\frac{1}{\eta^j} \vec{r}^{j+1} T \vec{r}^{j+1} & , i = j + 1 \\ 0 & , otherwise \end{cases}$$

Δηλαδή:

$$\beta_{ij} = \begin{cases} \frac{1}{\eta^{i-1}} \frac{\vec{r}^i T \vec{r}^i}{\vec{p}^{i-1} T A \vec{p}^{i-1}} & , i = j + 1 \\ 0 & , otherwise \end{cases}$$

Μέθοδος Συζυγών Κλίσεων (Conjugate Gradient, CG)



Αν:

$$\beta^i \longleftrightarrow \beta_{i,i-1}$$

Τότε:

$$\beta^i = \frac{1}{\eta^{i-1}} \frac{\vec{r}^i T \vec{r}^i}{\vec{p}^{i-1 T} A \vec{p}^{i-1}} \quad \begin{bmatrix} - & - & - & - \\ \beta^1 & - & - & - \\ - & \beta^2 & - & - \\ - & - & \beta^3 & - \end{bmatrix}$$

Και αφού:

$$\eta^{i-1} = \frac{\vec{p}^{i-1 T} \vec{r}^{i-1}}{\vec{p}^{i-1 T} A \vec{p}^{i-1}} \Rightarrow \eta^{i-1} \vec{p}^{i-1 T} A \vec{p}^{i-1} = \vec{p}^{i-1 T} \vec{r}^{i-1}$$

$$\beta^i = \frac{\vec{r}^i T \vec{r}^i}{\vec{p}^{i-1 T} \vec{r}^{i-1}}$$

Ή αφού:

$$\vec{p}^i T \vec{r}^i = \vec{r}^i T \vec{r}^i \Rightarrow \vec{p}^{i-1 T} \vec{r}^{i-1} = \vec{r}^{i-1 T} \vec{r}^{i-1}$$

$$\beta^i = \frac{\vec{r}^i T \vec{r}^i}{\vec{r}^{i-1 T} \vec{r}^{i-1}}$$

Μέθοδος Συζυγών Κλίσεων (Conjugate Gradient, CG)



Βήμα 0: Επιλογή αρχικής λύσης \vec{x}^0 . Υπολογισμός αρχικού υπολοίπου $\vec{r}^0 = \vec{b} - A\vec{x}^0$. Ορισμός αρχικής κατεύθυνσης ανίχνευσης $\vec{p}^0 = \vec{r}^0$. Δείκτης $n = 0$.

Βήμα 1: Υπολογισμός μεγέθους βήματος $\eta^n = \frac{\vec{r}^{nT}\vec{r}^n}{\vec{p}^{nT}A\vec{p}^n}$, (σχέση 3.47, σε συνδυασμό με τη σχέση 3.69).

Βήμα 2: Ανανέωση λύσης $\vec{x}^{n+1} = \vec{x}^n + \eta^n \vec{p}^n$.

Βήμα 3: Ανανέωση υπολοίπου $\vec{r}^{n+1} = \vec{r}^n - \eta^n A\vec{p}^n$, (σχέση 3.61).

Βήμα 4: Υπολογισμός συντελεστή $\beta^{n+1} = \frac{\vec{r}^{n+1T}\vec{r}^{n+1}}{\vec{r}^{nT}\vec{r}^n}$, (σχέση 3.70).

Βήμα 5: Ανανέωση διανύσματος κατεύθυνσης ανίχνευσης $\vec{p}^{n+1} = \vec{r}^{n+1} + \beta^{n+1} \vec{p}^n$, (προκύπτει από τη σχέση 3.54, για δείκτη $n+1$ αντί του n , με το \vec{r}^{n+1} αντί του \vec{u}^{n+1} λόγω της γνωστής παραδοχής και κρατώντας τη μοναδική μη-μηδενική τιμή του συντελεστή β από όλους τους όρους της άθροισης).

Βήμα 6: Ανανέωση τιμής δείκτη $n \leftarrow n+1$. Επιστροφή στο βήμα 1, μέχρι σύγκλισης.



CG σε Μη-Γραμμικά Προβλήματα – Fletcher-Reeves

Με:

$$\vec{r}^n = -\nabla F(\vec{x}^n)$$

Βήμα 0: Επιλογή αρχικής λύσης \vec{x}^0 . Υπολογισμός $F(\vec{x}^0)$. Υπολογισμός αρχικού υπολοίπου $\vec{r}^0 = -\nabla F(\vec{x}^0)$, (σχέση 3.71). Ορισμός αρχικής κατεύθυνσης ανίχνευσης $\vec{p}^0 = \vec{r}^0$. Δείκτης $n = 0$.

Βήμα 1: Αν $\vec{r}^n \neq 0$, υπολογισμός μεγέθους βήματος η^n με (ακριβή ή έστω προσεγγιστική) ανίχνευση κατά γραμμή, στην κατεύθυνση \vec{p}^n , της σχέσης $\min_{\eta^n > 0} F(\vec{x}^n + \eta^n \vec{p}^n)$.

Βήμα 2: Ανανέωση λύσης $\vec{x}^{n+1} = \vec{x}^n + \eta^n \vec{p}^n$.

Βήμα 3: Υπολογισμός $\nabla F(\vec{x}^{n+1})$.

Βήμα 4: Υπολογισμός συντελεστή β^{n+1} από τη σχέση

$$\beta_{FR}^{n+1} = \frac{\nabla F(\vec{x}^{n+1})^T \nabla F(\vec{x}^{n+1})}{\nabla F(\vec{x}^n)^T \nabla F(\vec{x}^n)} \quad (3.72)$$

Βήμα 5: Ανανέωση διανύσματος κατεύθυνσης ανίχνευσης $\vec{p}^{n+1} = -\nabla F(\vec{x}^{n+1}) + \beta_{FR}^{n+1} \vec{p}^n$.

Βήμα 6: Ανανέωση τιμής δείκτη $n \leftarrow n+1$. Επιστροφή στο βήμα 1, μέχρι σύγκλισης.

Υπολογισμός Εσσιανής (Hessian Matrix Computation)



Newton Methods :

$$b_i^{n+1} = b_i^n + db_i$$

$$\frac{d^2 F}{db_i db_j} db_j = -\frac{dF}{db_i}$$

Hessian Matrix Computation using the DD-DD method:

(Think “Discrete”, program Continuous Adjoint)

$$\frac{dF}{db_i} = \frac{\partial F}{\partial b_i} + \frac{\partial F}{\partial U_k} \frac{dU_k}{db_i}$$

$k=1, \dots, N$ design variables

$$\begin{aligned} \frac{d^2 F}{db_i db_j} &= \frac{\partial^2 F}{\partial b_i \partial b_j} + \frac{\partial^2 F}{\partial b_i \partial U_k} \frac{dU_k}{db_j} + \frac{\partial^2 F}{\partial U_k \partial b_j} \frac{dU_k}{db_i} \\ &+ \frac{\partial^2 F}{\partial U_k \partial U_m} \frac{dU_k}{db_i} \frac{dU_m}{db_j} + \frac{\partial F}{\partial U_k} \frac{d^2 U_k}{db_i db_j} \end{aligned}$$

$$\frac{dR_m}{db_i} = \frac{\partial R_m}{\partial b_i} + \frac{\partial R_m}{\partial U_k} \frac{dU_k}{db_i} = 0$$

$$\begin{aligned} \frac{d^2 R_n}{db_i db_j} &= \frac{\partial^2 R_n}{\partial b_i \partial b_j} + \frac{\partial^2 R_n}{\partial b_i \partial U_k} \frac{dU_k}{db_j} + \frac{\partial^2 R_n}{\partial U_k \partial b_j} \frac{dU_k}{db_i} \\ &+ \frac{\partial^2 R_n}{\partial U_k \partial U_m} \frac{dU_k}{db_i} \frac{dU_m}{db_j} + \frac{\partial R_n}{\partial U_k} \frac{d^2 U_k}{db_i db_j} = 0 \end{aligned}$$

► The cost for computing the Hessian via the DD-DD approach scales with N^2 .



Computation of the Hessian Matrix, via DD-AV

$$\frac{dR_m}{db_i} = \frac{\partial R_m}{\partial b_i} + \frac{\partial R_m}{\partial U_k} \frac{dU_k}{db_i} = 0 \quad \Rightarrow \quad \boxed{\frac{dU_k}{db_i}} \quad \boxed{N} \quad \text{System solutions (EFS)}$$

$$\frac{\partial F}{\partial U_k} + \hat{\Psi}_n \frac{\partial R_n}{\partial U_k} = 0 \quad \Rightarrow \quad \boxed{\hat{\Psi}_n} \quad \boxed{1} \quad \text{EFS}$$

The Adjoint equation is **the same** with that obtained for the Gradient !!!

$$\begin{aligned} \frac{d^2 \hat{F}}{db_i db_j} &= \frac{\partial^2 F}{\partial b_i \partial b_j} + \hat{\Psi}_n \frac{\partial^2 R_n}{\partial b_i \partial b_j} + \frac{\partial^2 F}{\partial U_k \partial U_m} \frac{dU_k}{db_i} \frac{dU_m}{db_j} + \hat{\Psi}_n \frac{\partial^2 R_n}{\partial U_k \partial U_m} \frac{dU_k}{db_i} \frac{dU_m}{db_j} \\ &+ \frac{\partial^2 F}{\partial b_i \partial U_k} \frac{dU_k}{db_j} + \hat{\Psi}_n \frac{\partial^2 R_n}{\partial b_i \partial U_k} \frac{dU_k}{db_j} + \frac{\partial^2 F}{\partial U_k \partial b_j} \frac{dU_k}{db_i} + \hat{\Psi}_n \frac{\partial^2 R_n}{\partial U_k \partial b_j} \frac{dU_k}{db_i} \quad \frac{d^2 F^\lambda}{db_i db_j} db_j^\lambda = - \frac{dF^\lambda}{db_i} \\ &+ \left(\frac{\partial F}{\partial U_k} + \hat{\Psi}_n \frac{\partial R_n}{\partial U_k} \right) \frac{d^2 U_k}{db_i db_j} \end{aligned}$$

- ▶ The cost per Newton cycle is $N+1+1=N+2$ EFS! Scales with N , not N^2 .
- ▶ DD-AV is the **most efficient** approach (among DD-DD, AV-DD, AV-AV)!



Truncated Newton Methods

Why?

- ▶ Create more efficient Hessian-based optimization schemes.
- ▶ Desirable cost per cycle $\ll N$ EFS, without damaging accuracy.

Inspired by:

The **Conjugate Gradient (CG)** method for solving systems of linear equations

$$Ax = q$$

requires only matrix-vector products.

$$k \leftarrow 0$$

$$x \leftarrow \text{init}()$$

$$r^0 \leftarrow Ax - q; p \leftarrow -r^0$$

while $r^k \neq 0$ and $k \leq M_{CG}$ do

$$\eta \leftarrow \frac{(r^k)^T r^k}{p^T Ap}$$

$$x \leftarrow x + \eta p$$

$$r^{k+1} \leftarrow r^k + \eta Ap$$

$$\beta \leftarrow \frac{(r^{k+1})^T r^{k+1}}{(r^k)^T r^k}$$

$$p \leftarrow -r_{k+1} + \beta p$$

$$k \leftarrow k + 1$$

end while



Truncated Newton Methods

```

k ← 0
bj ← init()
while k ≤ kmax do
  Un ← Flow Equations [1 EFS] ★
  Ψn ← Adjoint Equations [1 EFS] ★
  rj0 = dF/dbj ← Gradient Expression
  dbj0 ← init(0)
  pj ← -rj0
  m ← 0
  while rm ≠ 0 and m ≤ MCG do
    dUn/dbj pj ← DD (Flow Equations) [1 EFS] ★
    dΨn/dbj pj ← DD (Adjoint Equations) [1 EFS] ★
    wi = d2F/dbidbj pj ← Hessian Expression
    η ← (rimrim) / (pjwj)
    dbjm+1 ← dbjm + ηpj
    rjm+1 ← rjm + ηwj
    β ← (rim+1rim+1) / (rjmrjm)
    pj ← -rjm+1 + βpj
    m ← m + 1
  end while
  bj ← bj + dbj
  k ← k + 1
end while


```

$$b_i^{n+1} = b_i^n + db_i$$

$$\frac{d^2F}{db_i db_j} db_j = -\frac{dF}{db_i}$$



Total Cost = 2 + 2M_{CG} << N





Truncated Newton Methods (Εξήγηση)

$$\left. \begin{aligned} \frac{\delta F}{\delta b_i} &= \frac{\partial F}{\partial b_i} + \Psi_m \frac{\partial R_m}{\partial b_i} \\ \frac{\delta R_m}{\delta b_i} &= \frac{\partial R_m}{\partial b_i} + \frac{\partial R_m}{\partial U_k} \frac{\delta U_k}{\delta b_i} = 0. \end{aligned} \right\} \begin{aligned} R_k^\Psi &= \frac{\partial F}{\partial U_k} + \Psi_m \frac{\partial R_m}{\partial U_k} = 0 \\ \frac{\delta F}{\delta b_i} &= \frac{\partial F}{\partial b_i} + \Psi_m \frac{\partial R_m}{\partial b_i} \end{aligned}$$

$$\begin{aligned} \frac{\delta^2 F}{\delta b_i \delta b_j} s_j &= \frac{\partial^2 F}{\partial b_i \partial b_j} s_j + \frac{\partial^2 F}{\partial b_i \partial U_k} \left(\frac{\delta U_k}{\delta b_j} s_j \right) + \Psi_m \frac{\partial^2 R_m}{\partial b_i \partial b_j} s_j + \Psi_m \frac{\partial^2 R_m}{\partial b_i \partial U_k} \left(\frac{\delta U_k}{\delta b_j} s_j \right) \\ &\quad + \left(\frac{\delta \Psi_m}{\delta b_j} s_j \right) \frac{\partial R_m}{\partial b_i}. \end{aligned}$$

ΣΥΜΠΕΡΑΣΜΑ: Χρειαζόμαστε γινόμενα των κλίσεων των πρωτευουσών και των συζυγών μεταβλητών με κάποιο διάνυσμα και όχι τις κλίσεις αυτές καθαυτές!!!!



Truncated Newton Methods (Εξήγηση)

Υπολογισμός του : $\left(\frac{\delta U_k}{\delta b_j} s_j \right)$

$$\frac{\partial R_m}{\partial b_j} s_j + \frac{\partial R_m}{\partial U_k} \left(\frac{\delta U_k}{\delta b_j} s_j \right) = 0,$$

... με κόστος περίπου αυτό του να λυθούν οι εξισώσεις ροής.

Υπολογισμός του :

$$\frac{\partial F}{\partial U_k} + \Psi_m \frac{\partial R_m}{\partial U_k} = 0$$

$$\frac{\partial^2 F}{\partial U_n \partial b_j} s_j + \frac{\partial^2 F}{\partial U_n \partial U_k} \left(\frac{\delta U_k}{\delta b_j} s_j \right) + \Psi_m \frac{\partial^2 R_m}{\partial U_n \partial b_j} s_j + \Psi_m \frac{\partial^2 R_m}{\partial U_n \partial U_k} \left(\frac{\delta U_k}{\delta b_j} s_j \right) + \left(\frac{\delta \Psi_m}{\delta b_j} s_j \right) \frac{\partial R_m}{\partial U_n} = 0$$

... με κόστος περίπου αυτό του να λυθούν οι εξισώσεις ροής.



Ότι παρουσιάστηκε για τη Διακριτή Συζυγή Μέθοδο,
εφαρμόζεται εξίσου και με τη Συνεχή Συζυγή Μέθοδο.

Απλώς, προτιμήθηκε η παρουσίαση να γίνει με τη Διακριτή
Μέθοδο, γιατί είναι περισσότερο σύντομη και εποπτική!