

Mittelineaarsete võrrandisüsteemide ligikaudne lahendamine

Vaatleme mittelineaarset võrrandisüsteemi

$$\begin{cases} f_1(x_1; x_2; \dots; x_m) = 0 \\ f_2(x_1; x_2; \dots; x_m) = 0 \\ \dots \\ f_m(x_1; x_2; \dots; x_m) = 0 \end{cases}$$

kus f_1, \dots, f_m on funktsioonid.

Olgu otsitavate vektor $x = (x_1; x_2; \dots; x_m)$.

Võrrandisüsteemi vasakust poolest saab moodustada vektori $F(x) = (f_1(x); f_2(x); \dots; f_m(x))$. Vektor $F(x)$ sõltub vektorist x , seega on suurus F vektorfunktsioon ning süsteemi saab kirja panna vektorvõrrandiga $F(x) = 0$.

Mittelineaarsete võrrandisüsteemide ligikaudne lahendamine

Vaatleme mittelineaarset võrrandisüsteemi

$$\begin{cases} f_1(x_1; x_2; \dots; x_m) = 0 \\ f_2(x_1; x_2; \dots; x_m) = 0 \\ \dots \\ f_m(x_1; x_2; \dots; x_m) = 0 \end{cases}$$

kus f_1, \dots, f_m on funktsioonid.

Olgu otsitavate vektor $x = (x_1; x_2; \dots; x_m)$.

Võrrandisüsteemi vasakust poolest saab moodustada vektori $F(x) = (f_1(x); f_2(x); \dots; f_m(x))$. Vektor $F(x)$ sõltub vektorist x , seega on suurus F vektorfunktsioon ning süsteemi saab kirja panna vektorvõrrandiga $F(x) = 0$.

Mittelineaarsete võrrandisüsteemide ligikaudne lahendamine

Vaatleme mittelineaarset võrrandisüsteemi

$$\begin{cases} f_1(x_1; x_2; \dots; x_m) = 0 \\ f_2(x_1; x_2; \dots; x_m) = 0 \\ \dots \\ f_m(x_1; x_2; \dots; x_m) = 0 \end{cases}$$

kus f_1, \dots, f_m on funktsioonid.

Olgu otsitavate vektor $x = (x_1; x_2; \dots; x_m)$.

Võrrandisüsteemi vasakust poolest saab moodustada vektori $F(x) = (f_1(x); f_2(x); \dots; f_m(x))$. Vektor $F(x)$ sõltub vektorist x , seega on suurus F vektorfunktsioon ning süsteemi saab kirja panna vektorvõrrandiga $F(x) = 0$.

Mittelineaarsete võrrandisüsteemide ligikaudne lahendamine

Vaatleme mittelineaarset võrrandisüsteemi

$$\begin{cases} f_1(x_1; x_2; \dots; x_m) = 0 \\ f_2(x_1; x_2; \dots; x_m) = 0 \\ \dots \\ f_m(x_1; x_2; \dots; x_m) = 0 \end{cases}$$

kus f_1, \dots, f_m on funktsioonid.

Olgu otsitavate vektor $x = (x_1; x_2; \dots; x_m)$.

Võrrandisüsteemi vasakust poolest saab moodustada vektori $F(x) = (f_1(x); f_2(x); \dots; f_m(x))$. Vektor $F(x)$ sõltub vektorist x , seega on suurus F vektorfunktsioon ning süsteemi saab kirja panna vektorvõrrandiga $F(x) = 0$.

Harilik iteratsioonimeetod

Hariliku iteratsioonimeetodi saamiseks on vaja süsteem $F(x) = 0$ viia kujule $x = G(x)$, kus $G(x) = (g_1(x); g_2(x); \dots; g_m(x))$, ehk

$$\begin{cases} x_1 = g_1(x_1; x_2; \dots; x_m) \\ x_2 = g_2(x_1; x_2; \dots; x_m) \\ \dots \\ x_m = g_m(x_1; x_2; \dots; x_m) \end{cases}$$

Kui on antud alglähend $x^0 = (x_1^0, x_2^0, \dots, x_m^0)$, siis järgmise lähendi saab leida eeskirjast $x^1 = G(x^0)$, järgmisena $x^2 = G(x^1)$, jne.

Hariliku iteratsioonimeetodi kuju on seega

$$x^n = G(x^{n-1})$$

Harilik iteratsioonimeetod

Hariliku iteratsioonimeetodi saamiseks on vaja süsteem $F(x) = 0$ viia kujule $x = G(x)$, kus $G(x) = (g_1(x); g_2(x); \dots; g_m(x))$,
ehk

$$\begin{cases} x_1 = g_1(x_1; x_2; \dots; x_m) \\ x_2 = g_2(x_1; x_2; \dots; x_m) \\ \dots \\ x_m = g_m(x_1; x_2; \dots; x_m) \end{cases}$$

Kui on antud alglähend $x^0 = (x_1^0, x_2^0, \dots, x_m^0)$, siis järgmise lähendi saab leida eeskirjast $x^1 = G(x^0)$, järgmisena $x^2 = G(x^1)$, jne.

Hariliku iteratsioonimeetodi kuju on seega

$$x^n = G(x^{n-1})$$

Harilik iteratsioonimeetod

Hariliku iteratsioonimeetodi saamiseks on vaja süsteem $F(x) = 0$ viia kujule $x = G(x)$, kus $G(x) = (g_1(x); g_2(x); \dots; g_m(x))$, ehk

$$\begin{cases} x_1 = g_1(x_1; x_2; \dots; x_m) \\ x_2 = g_2(x_1; x_2; \dots; x_m) \\ \dots \\ x_m = g_m(x_1; x_2; \dots; x_m) \end{cases}$$

Kui on antud alglähend $x^0 = (x_1^0, x_2^0, \dots, x_m^0)$, siis järgmise lähendi saab leida eeskirjast $x^1 = G(x^0)$, järgmisena $x^2 = G(x^1)$, jne.

Hariliku iteratsioonimeetodi kuju on seega

$$x^n = G(x^{n-1})$$

Harilik iteratsioonimeetod

Hariliku iteratsioonimeetodi saamiseks on vaja süsteem $F(x) = 0$ viia kujule $x = G(x)$, kus $G(x) = (g_1(x); g_2(x); \dots; g_m(x))$, ehk

$$\begin{cases} x_1 = g_1(x_1; x_2; \dots; x_m) \\ x_2 = g_2(x_1; x_2; \dots; x_m) \\ \dots \\ x_m = g_m(x_1; x_2; \dots; x_m) \end{cases}$$

Kui on antud alglähend $x^0 = (x_1^0, x_2^0, \dots, x_m^0)$, siis järgmise lähendi saab leida eeskirjast $x^1 = G(x^0)$, järgmisena $x^2 = G(x^1)$, jne.

Hariliku iteratsioonimeetodi kuju on seega

$$x^n = G(x^{n-1})$$

Harilik iteratsioonimeetod

Hariliku iteratsioonimeetodi saamiseks on vaja süsteem $F(x) = 0$ viia kujule $x = G(x)$, kus $G(x) = (g_1(x); g_2(x); \dots; g_m(x))$, ehk

$$\begin{cases} x_1 = g_1(x_1; x_2; \dots; x_m) \\ x_2 = g_2(x_1; x_2; \dots; x_m) \\ \dots \\ x_m = g_m(x_1; x_2; \dots; x_m) \end{cases}$$

Kui on antud alglähend $x^0 = (x_1^0, x_2^0, \dots, x_m^0)$, siis järgmise lähendi saab leida eeskirjast $x^1 = G(x^0)$, järgmisena $x^2 = G(x^1)$, jne.

Hariliku iteratsioonimeetodi kuju on seega

$$x^n = G(x^{n-1})$$

või võrrandite kaupa

$$\begin{cases} x_1^n = g_1(x_1^{n-1}; x_2^{n-1}; \dots; x_m^{n-1}) \\ x_2^n = g_2(x_1^{n-1}; x_2^{n-1}; \dots; x_m^{n-1}) \\ \dots \\ x_m^n = g_m(x_1^{n-1}; x_2^{n-1}; \dots; x_m^{n-1}) \end{cases}$$

Siit on lihtne tuletada **Seideli iteratsioonimeetodi** (või ka Gaussi-Seideli iteratsioonimeetod) eeskiri:

või võrrandite kaupa

$$\begin{cases} x_1^n = g_1(x_1^{n-1}; x_2^{n-1}; \dots; x_m^{n-1}) \\ x_2^n = g_2(x_1^{n-1}; x_2^{n-1}; \dots; x_m^{n-1}) \\ \dots \\ x_m^n = g_m(x_1^{n-1}; x_2^{n-1}; \dots; x_m^{n-1}) \end{cases}$$

Siit on lihtne tuletada **Seideli iteratsioonimeetodi** (või ka Gaussi-Seideli iteratsioonimeetod) eeskiri:

$$\begin{cases} x_1^n = g_1(x_1^{n-1}; x_2^{n-1}; x_3^{n-1}; \dots; x_m^{n-1}) \\ x_2^n = g_2(x_1^n; x_2^{n-1}; x_3^{n-1} \dots; x_m^{n-1}) \\ x_3^n = g_3(x_1^n; x_2^n; x_3^{n-1} \dots; x_m^{n-1}) \\ \dots \\ x_m^n = g_m(x_1^n; x_2^n; \dots; x_m^{n-1}) \end{cases}$$

Olgu meil teada süsteemi $F(x) = 0$ täpne lahend x^* , siis ka $x^* = G(x^*)$. Lähendi x^n erinevust täpsest lahendist x^* iseloomustab nende vaheline kaugus $\|x^n - x^*\|$.

Kui

$$\lim_{n \rightarrow \infty} \|x^n - x^*\| = 0,$$

siis koondub lähend x^n täpseks lahendiks x^* .

$$\begin{cases} x_1^n = g_1(x_1^{n-1}; x_2^{n-1}; x_3^{n-1}; \dots; x_m^{n-1}) \\ x_2^n = g_2(x_1^n; x_2^{n-1}; x_3^{n-1} \dots; x_m^{n-1}) \\ x_3^n = g_3(x_1^n; x_2^n; x_3^{n-1} \dots; x_m^{n-1}) \\ \dots \\ x_m^n = g_m(x_1^n; x_2^n; \dots; x_m^{n-1}) \end{cases}$$

Olgu meil teada süsteemi $F(x) = 0$ täpne lahend x^* , siis ka $x^* = G(x^*)$. Lähendi x^n erinevust täpsest lahendist x^* iseloomustab nende vaheline kaugus $\|x^n - x^*\|$.

Kui

$$\lim_{n \rightarrow \infty} \|x^n - x^*\| = 0,$$

siis koondub lähend x^n täpseks lahendiks x^* .

$$\begin{cases} x_1^n = g_1(x_1^{n-1}; x_2^{n-1}; x_3^{n-1}; \dots; x_m^{n-1}) \\ x_2^n = g_2(x_1^n; x_2^{n-1}; x_3^{n-1} \dots; x_m^{n-1}) \\ x_3^n = g_3(x_1^n; x_2^n; x_3^{n-1} \dots; x_m^{n-1}) \\ \dots \\ x_m^n = g_m(x_1^n; x_2^n; \dots; x_m^{n-1}) \end{cases}$$

Olgu meil teada süsteemi $F(x) = 0$ täpne lahend x^* , siis ka $x^* = G(x^*)$. Lähendi x^n erinevust täpsest lahendist x^* iseloomustab nende vaheline kaugus $\|x^n - x^*\|$.

Kui

$$\lim_{n \rightarrow \infty} \|x^n - x^*\| = 0,$$

siis koondub lähend x^n täpseks lahendiks x^* .

Oluline tingimus koondumiseks

$$\|G'(x)\| \leq q < 1.$$

Teoreem

Leidugu süsteemi $F(x) = 0$ lahendit x^* sisaldav kera B , milles on täidetud võrratus $\|G'(x)\| \leq q < 1$. Peale selle eeldame, et vektorfunktsioon $G(x)$ ei vii kerast B välja, st iga $x \in B$ korral $G(x) \in B$. Olgu alglähend x^0 valitud hulgast B , siis koondub nii hariliku kui ka Seideli iteratsioonimeetodiga arvutatud lähendite jada x^n täpseks lahendiks x^* . Seejuures kehtib veahinnang

$$\|x^n - x^*\| \leq \frac{q^n}{1 - q} \|x^1 - x^0\|.$$

Oluline tingimus koondumiseks

$$\|G'(x)\| \leq q < 1.$$

Teoreem

Leidugu süsteemi $F(x) = 0$ lahendit x^ sisaldav kera B , milles on täidetud võrratus $\|G'(x)\| \leq q < 1$. Peale selle eeldame, et vektorfunktsioon $G(x)$ ei vii kerast B välja, st iga $x \in B$ korral $G(x) \in B$. Olgu alglähend x^0 valitud hulgast B , siis koondub nii hariliku kui ka Seideli iteratsioonimeetodiga arvutatud lähendite jada x^n täpseks lahendiks x^* . Seejuures kehtib veahinnang*

$$\|x^n - x^*\| \leq \frac{q^n}{1 - q} \|x^1 - x^0\|.$$

Harilik iteratsioonimeetod lineaarsete süsteemide korral

Vaatame süsteemi

$$\begin{cases} a_{11}x_1 + a_{12}x_2 + \dots + a_{1m}x_m = y_1 \\ a_{21}x_1 + a_{22}x_2 + \dots + a_{2m}x_m = y_2 \\ \dots \\ a_{m1}x_1 + a_{m2}x_2 + \dots + a_{mm}x_m = y_m. \end{cases}$$

Seda süsteemi võib vaadelda kui erijuhtu mittelineaarsest süsteemist

$$\begin{cases} f_1(x_1; x_2; \dots; x_m) = 0 \\ f_2(x_1; x_2; \dots; x_m) = 0 \\ \dots \\ f_m(x_1; x_2; \dots; x_m) = 0 \end{cases},$$

kus $f_i(x_1, x_2, \dots, x_m) = a_{i1}x_1 + a_{i2}x_2 + \dots + a_{im}x_m - y_i$, $i = 1, 2, \dots, m$.

Harilik iteratsioonimeetod lineaarsete süsteemide korral

Vaatame süsteemi

$$\begin{cases} a_{11}x_1 + a_{12}x_2 + \dots + a_{1m}x_m = y_1 \\ a_{21}x_1 + a_{22}x_2 + \dots + a_{2m}x_m = y_2 \\ \dots \\ a_{m1}x_1 + a_{m2}x_2 + \dots + a_{mm}x_m = y_m. \end{cases}$$

Seda süsteemi võib vaadelda kui erijuhtu mittelineaarsest süsteemist

$$\begin{cases} f_1(x_1; x_2; \dots; x_m) = 0 \\ f_2(x_1; x_2; \dots; x_m) = 0 \\ \dots \\ f_m(x_1; x_2; \dots; x_m) = 0 \end{cases},$$

kus $f_i(x_1, x_2, \dots, x_m) = a_{i1}x_1 + a_{i2}x_2 + \dots + a_{im}x_m - y_i$, $i = 1, 2, \dots, m$.

Harilik iteratsioonimeetod lineaarsete süsteemide korral

Vaatame süsteemi

$$\begin{cases} a_{11}x_1 + a_{12}x_2 + \dots + a_{1m}x_m = y_1 \\ a_{21}x_1 + a_{22}x_2 + \dots + a_{2m}x_m = y_2 \\ \dots \\ a_{m1}x_1 + a_{m2}x_2 + \dots + a_{mm}x_m = y_m. \end{cases}$$

Seda süsteemi võib vaadelda kui erijuhtu mittelineaarsest süsteemist

$$\begin{cases} f_1(x_1; x_2; \dots; x_m) = 0 \\ f_2(x_1; x_2; \dots; x_m) = 0 \\ \dots \\ f_m(x_1; x_2; \dots; x_m) = 0 \end{cases},$$

kus $f_i(x_1, x_2, \dots, x_m) = a_{i1}x_1 + a_{i2}x_2 + \dots + a_{im}x_m - y_i$, $i = 1, 2, \dots, m$.

Leiame lineaarse süsteemi jaoks hariliku iteratsioonimeetodi ja Seideli meetodi kuju. Selleks järjestame võrrandid ümber nii, et $a_{ij} \neq 0$ ning jagame i -nda võrrandi kordajaga a_{ij} läbi. Saame

$$\begin{cases} X_1 + \frac{a_{12}}{a_{11}} X_2 + \frac{a_{13}}{a_{11}} X_3 + \dots + \frac{a_{1m}}{a_{11}} X_m = \frac{y_1}{a_{11}} \\ \frac{a_{21}}{a_{22}} X_1 + X_2 + \frac{a_{23}}{a_{22}} X_3 + \dots + \frac{a_{2m}}{a_{22}} X_m = \frac{y_2}{a_{22}} \\ \dots \\ \frac{a_{m1}}{a_{mm}} X_1 + \frac{a_{m2}}{a_{mm}} X_2 + \frac{a_{m3}}{a_{mm}} X_3 + \dots + X_m = \frac{y_m}{a_{mm}}. \end{cases}$$

Siit

$$\begin{cases} X_1 = -\frac{a_{12}}{a_{11}} X_2 - \frac{a_{13}}{a_{11}} X_3 - \dots - \frac{a_{1m}}{a_{11}} X_m + \frac{y_1}{a_{11}} \\ X_2 = -\frac{a_{21}}{a_{22}} X_1 - \frac{a_{23}}{a_{22}} X_3 - \dots - \frac{a_{2m}}{a_{22}} X_m + \frac{y_2}{a_{22}} \\ \dots \\ X_m = -\frac{a_{m1}}{a_{mm}} X_1 - \frac{a_{m2}}{a_{mm}} X_2 - \frac{a_{m3}}{a_{mm}} X_3 - \dots - \frac{a_{m,m-1}}{a_{mm}} X_{m-1} + \frac{y_m}{a_{mm}}. \end{cases}$$

Leiame lineaarse süsteemi jaoks hariliku iteratsioonimeetodi ja Seideli meetodi kuju. Selleks järjestame võrrandid ümber nii, et $a_{ij} \neq 0$ ning jagame i -nda võrrandi kordajaga a_{ij} läbi. Saame

$$\begin{cases} X_1 + \frac{a_{12}}{a_{11}} X_2 + \frac{a_{13}}{a_{11}} X_3 + \dots + \frac{a_{1m}}{a_{11}} X_m = \frac{y_1}{a_{11}} \\ \frac{a_{21}}{a_{22}} X_1 + X_2 + \frac{a_{23}}{a_{22}} X_3 + \dots + \frac{a_{2m}}{a_{22}} X_m = \frac{y_2}{a_{22}} \\ \dots \\ \frac{a_{m1}}{a_{mm}} X_1 + \frac{a_{m2}}{a_{mm}} X_2 + \frac{a_{m3}}{a_{mm}} X_3 + \dots + X_m = \frac{y_m}{a_{mm}}. \end{cases}$$

Siit

$$\begin{cases} X_1 = -\frac{a_{12}}{a_{11}} X_2 - \frac{a_{13}}{a_{11}} X_3 - \dots - \frac{a_{1m}}{a_{11}} X_m + \frac{y_1}{a_{11}} \\ X_2 = -\frac{a_{21}}{a_{22}} X_1 - \frac{a_{23}}{a_{22}} X_3 - \dots - \frac{a_{2m}}{a_{22}} X_m + \frac{y_2}{a_{22}} \\ \dots \\ X_m = -\frac{a_{m1}}{a_{mm}} X_1 - \frac{a_{m2}}{a_{mm}} X_2 - \frac{a_{m3}}{a_{mm}} X_3 - \dots - \frac{a_{m,m-1}}{a_{mm}} X_{m-1} + \frac{y_m}{a_{mm}}. \end{cases}$$

Leiame lineaarse süsteemi jaoks hariliku iteratsioonimeetodi ja Seideli meetodi kuju. Selleks järjestame võrrandid ümber nii, et $a_{ii} \neq 0$ ning jagame i -nda võrrandi kordajaga a_{ii} läbi. Saame

$$\begin{cases} X_1 + \frac{a_{12}}{a_{11}} X_2 + \frac{a_{13}}{a_{11}} X_3 + \dots + \frac{a_{1m}}{a_{11}} X_m = \frac{y_1}{a_{11}} \\ \frac{a_{21}}{a_{22}} X_1 + X_2 + \frac{a_{23}}{a_{22}} X_3 + \dots + \frac{a_{2m}}{a_{22}} X_m = \frac{y_2}{a_{22}} \\ \dots \\ \frac{a_{m1}}{a_{mm}} X_1 + \frac{a_{m2}}{a_{mm}} X_2 + \frac{a_{m3}}{a_{mm}} X_3 + \dots + X_m = \frac{y_m}{a_{mm}}. \end{cases}$$

Siit

$$\begin{cases} X_1 = -\frac{a_{12}}{a_{11}} X_2 - \frac{a_{13}}{a_{11}} X_3 - \dots - \frac{a_{1m}}{a_{11}} X_m + \frac{y_1}{a_{11}} \\ X_2 = -\frac{a_{21}}{a_{22}} X_1 - \frac{a_{23}}{a_{22}} X_3 - \dots - \frac{a_{2m}}{a_{22}} X_m + \frac{y_2}{a_{22}} \\ \dots \\ X_m = -\frac{a_{m1}}{a_{mm}} X_1 - \frac{a_{m2}}{a_{mm}} X_2 - \frac{a_{m3}}{a_{mm}} X_3 - \dots - \frac{a_{m,m-1}}{a_{mm}} X_{m-1} + \frac{y_m}{a_{mm}}. \end{cases}$$

Leiame lineaarse süsteemi jaoks hariliku iteratsioonimeetodi ja Seideli meetodi kuju. Selleks järjestame võrrandid ümber nii, et $a_{ii} \neq 0$ ning jagame i -nda võrrandi kordajaga a_{ii} läbi. Saame

$$\begin{cases} x_1 + \frac{a_{12}}{a_{11}} x_2 + \frac{a_{13}}{a_{11}} x_3 + \dots + \frac{a_{1m}}{a_{11}} x_m = \frac{y_1}{a_{11}} \\ \frac{a_{21}}{a_{22}} x_1 + x_2 + \frac{a_{23}}{a_{22}} x_3 + \dots + \frac{a_{2m}}{a_{22}} x_m = \frac{y_2}{a_{22}} \\ \dots \\ \frac{a_{m1}}{a_{mm}} x_1 + \frac{a_{m2}}{a_{mm}} x_2 + \frac{a_{m3}}{a_{mm}} x_3 + \dots + x_m = \frac{y_m}{a_{mm}}. \end{cases}$$

Siit

$$\begin{cases} x_1 = -\frac{a_{12}}{a_{11}} x_2 - \frac{a_{13}}{a_{11}} x_3 - \dots - \frac{a_{1m}}{a_{11}} x_m + \frac{y_1}{a_{11}} \\ x_2 = -\frac{a_{21}}{a_{22}} x_1 - \frac{a_{23}}{a_{22}} x_3 - \dots - \frac{a_{2m}}{a_{22}} x_m + \frac{y_2}{a_{22}} \\ \dots \\ x_m = -\frac{a_{m1}}{a_{mm}} x_1 - \frac{a_{m2}}{a_{mm}} x_2 - \frac{a_{m3}}{a_{mm}} x_3 - \dots - \frac{a_{m,m-1}}{a_{mm}} x_{m-1} + \frac{y_m}{a_{mm}}. \end{cases}$$

Leiame lineaarse süsteemi jaoks hariliku iteratsioonimeetodi ja Seideli meetodi kuju. Selleks järjestame võrrandid ümber nii, et $a_{ii} \neq 0$ ning jagame i -nda võrrandi kordajaga a_{ii} läbi. Saame

$$\begin{cases} x_1 + \frac{a_{12}}{a_{11}}x_2 + \frac{a_{13}}{a_{11}}x_3 + \dots + \frac{a_{1m}}{a_{11}}x_m = \frac{y_1}{a_{11}} \\ \frac{a_{21}}{a_{22}}x_1 + x_2 + \frac{a_{23}}{a_{22}}x_3 + \dots + \frac{a_{2m}}{a_{22}}x_m = \frac{y_2}{a_{22}} \\ \dots \\ \frac{a_{m1}}{a_{mm}}x_1 + \frac{a_{m2}}{a_{mm}}x_2 + \frac{a_{m3}}{a_{mm}}x_3 + \dots + x_m = \frac{y_m}{a_{mm}}. \end{cases}$$

Siit

$$\begin{cases} x_1 = -\frac{a_{12}}{a_{11}}x_2 - \frac{a_{13}}{a_{11}}x_3 - \dots - \frac{a_{1m}}{a_{11}}x_m + \frac{y_1}{a_{11}} \\ x_2 = -\frac{a_{21}}{a_{22}}x_1 - \frac{a_{23}}{a_{22}}x_3 - \dots - \frac{a_{2m}}{a_{22}}x_m + \frac{y_2}{a_{22}} \\ \dots \\ x_m = -\frac{a_{m1}}{a_{mm}}x_1 - \frac{a_{m2}}{a_{mm}}x_2 - \frac{a_{m3}}{a_{mm}}x_3 - \dots - \frac{a_{m,m-1}}{a_{mm}}x_{m-1} + \frac{y_m}{a_{mm}}. \end{cases}$$

Seega hariliku iteratsioonimeetodi kuju lineaarse võrrandisüsteemi jaoks on

$$\begin{cases} x_1^n = -\frac{a_{12}}{a_{11}}x_2^{n-1} - \frac{a_{13}}{a_{11}}x_3^{n-1} - \dots - \frac{a_{1m}}{a_{11}}x_m^{n-1} + \frac{y_1}{a_{11}} \\ x_2^n = -\frac{a_{21}}{a_{22}}x_1^{n-1} - \frac{a_{23}}{a_{22}}x_3^{n-1} - \dots - \frac{a_{2m}}{a_{22}}x_m^{n-1} + \frac{y_2}{a_{22}} \\ \dots \\ x_m^n = -\frac{a_{m1}}{a_{mm}}x_1^{n-1} - \frac{a_{m2}}{a_{mm}}x_2^{n-1} - \frac{a_{m3}}{a_{mm}}x_3^{n-1} - \dots - \frac{a_{m,m-1}}{a_{mm}}x_{m-1}^{n-1} + \frac{y_m}{a_{mm}}. \end{cases}$$

ja Seideli meetodi kuju on

$$\begin{cases} x_1^n = -\frac{a_{12}}{a_{11}}x_2^{n-1} - \frac{a_{13}}{a_{11}}x_3^{n-1} - \dots - \frac{a_{1m}}{a_{11}}x_m^{n-1} + \frac{y_1}{a_{11}} \\ x_2^n = -\frac{a_{21}}{a_{22}}x_1^n - \frac{a_{23}}{a_{22}}x_3^{n-1} - \dots - \frac{a_{2m}}{a_{22}}x_m^{n-1} + \frac{y_2}{a_{22}} \\ \dots \\ x_m^n = -\frac{a_{m1}}{a_{mm}}x_1^n - \frac{a_{m2}}{a_{mm}}x_2^n - \frac{a_{m3}}{a_{mm}}x_3^n - \dots - \frac{a_{m,m-1}}{a_{mm}}x_{m-1}^n + \frac{y_m}{a_{mm}}. \end{cases}$$

Seega hariliku iteratsioonimeetodi kuju lineaarse võrrandisüsteemi jaoks on

$$\begin{cases} x_1^n = -\frac{a_{12}}{a_{11}}x_2^{n-1} - \frac{a_{13}}{a_{11}}x_3^{n-1} - \dots - \frac{a_{1m}}{a_{11}}x_m^{n-1} + \frac{y_1}{a_{11}} \\ x_2^n = -\frac{a_{21}}{a_{22}}x_1^{n-1} - \frac{a_{23}}{a_{22}}x_3^{n-1} - \dots - \frac{a_{2m}}{a_{22}}x_m^{n-1} + \frac{y_2}{a_{22}} \\ \dots \\ x_m^n = -\frac{a_{m1}}{a_{mm}}x_1^{n-1} - \frac{a_{m2}}{a_{mm}}x_2^{n-1} - \frac{a_{m3}}{a_{mm}}x_3^{n-1} - \dots - \frac{a_{m,m-1}}{a_{mm}}x_{m-1}^{n-1} + \frac{y_m}{a_{mm}}. \end{cases}$$

ja Seideli meetodi kuju on

$$\begin{cases} x_1^n = -\frac{a_{12}}{a_{11}}x_2^{n-1} - \frac{a_{13}}{a_{11}}x_3^{n-1} - \dots - \frac{a_{1m}}{a_{11}}x_m^{n-1} + \frac{y_1}{a_{11}} \\ x_2^n = -\frac{a_{21}}{a_{22}}x_1^n - \frac{a_{23}}{a_{22}}x_3^{n-1} - \dots - \frac{a_{2m}}{a_{22}}x_m^{n-1} + \frac{y_2}{a_{22}} \\ \dots \\ x_m^n = -\frac{a_{m1}}{a_{mm}}x_1^n - \frac{a_{m2}}{a_{mm}}x_2^n - \frac{a_{m3}}{a_{mm}}x_3^n - \dots - \frac{a_{m,m-1}}{a_{mm}}x_{m-1}^n + \frac{y_m}{a_{mm}}. \end{cases}$$

Seega hariliku iteratsioonimeetodi kuju lineaarse võrrandisüsteemi jaoks on

$$\begin{cases} x_1^n = -\frac{a_{12}}{a_{11}}x_2^{n-1} - \frac{a_{13}}{a_{11}}x_3^{n-1} - \dots - \frac{a_{1m}}{a_{11}}x_m^{n-1} + \frac{y_1}{a_{11}} \\ x_2^n = -\frac{a_{21}}{a_{22}}x_1^{n-1} - \frac{a_{23}}{a_{22}}x_3^{n-1} - \dots - \frac{a_{2m}}{a_{22}}x_m^{n-1} + \frac{y_2}{a_{22}} \\ \dots \\ x_m^n = -\frac{a_{m1}}{a_{mm}}x_1^{n-1} - \frac{a_{m2}}{a_{mm}}x_2^{n-1} - \frac{a_{m3}}{a_{mm}}x_3^{n-1} - \dots - \frac{a_{m,m-1}}{a_{mm}}x_{m-1}^{n-1} + \frac{y_m}{a_{mm}}. \end{cases}$$

ja Seideli meetodi kuju on

$$\begin{cases} x_1^n = -\frac{a_{12}}{a_{11}}x_2^{n-1} - \frac{a_{13}}{a_{11}}x_3^{n-1} - \dots - \frac{a_{1m}}{a_{11}}x_m^{n-1} + \frac{y_1}{a_{11}} \\ x_2^n = -\frac{a_{21}}{a_{22}}x_1^n - \frac{a_{23}}{a_{22}}x_3^{n-1} - \dots - \frac{a_{2m}}{a_{22}}x_m^{n-1} + \frac{y_2}{a_{22}} \\ \dots \\ x_m^n = -\frac{a_{m1}}{a_{mm}}x_1^n - \frac{a_{m2}}{a_{mm}}x_2^n - \frac{a_{m3}}{a_{mm}}x_3^n - \dots - \frac{a_{m,m-1}}{a_{mm}}x_{m-1}^n + \frac{y_m}{a_{mm}}. \end{cases}$$

Sellisel kujul harilik iteratsioonimeetod ja Seideli meetod koondub, kui maatriks A on domineeriva peadiagonaaliga, st

$$|a_{ii}| > \sum_{j=1}^m |a_{ij}|, \quad j \neq i.$$

Sellisel kujul harilik iteratsioonimeetod ja Seideli meetod koondub, kui maatriks A on domineeriva peadiagonaaliga, st

$$|a_{ii}| > \sum_{j=1}^m |a_{ij}|, \quad j \neq i.$$

Sellisel kujul harilik iteratsioonimeetod ja Seideli meetod koondub, kui maatriks A on domineeriva peadiagonaaliga, st

$$|a_{ii}| > \sum_{j=1}^m |a_{ij}|, \quad j \neq i.$$

Newtoni meetod

Võrrandi $f(x) = 0$ korral oli Newtoni meetodi eeskiri

$$x_n = x_{n-1} - \frac{f(x_{n-1})}{f'(x_{n-1})}.$$

Seda meetodit saab üldistada ka mittelineaarsetele võrrandisüsteemidele kujul $F(x) = 0$. Siin

$F(X) = (f_1(x), f_2(x), \dots, f_m(x))$ on vektorfunktsioon ning otsitavate vektor on $x = (x_1, x_2, \dots, x_m)$.

Newtoni meetodi algoritm

$$x^n = x^{n-1} - [F'(x^{n-1})]^{-1} F(x^{n-1}),$$

kus $x^{n-1} = (x_1^{n-1}, x_2^{n-1}, \dots, x_m^{n-1})$ ja $x^n = (x_1^n, x_2^n, \dots, x_m^n)$ on kaks järjestikust lähendit.

Newtoni meetod

Võrrandi $f(x) = 0$ korral oli Newtoni meetodi eeskiri

$$x_n = x_{n-1} - \frac{f(x_{n-1})}{f'(x_{n-1})}.$$

Seda meetodit saab üldistada ka mittelineaarsetele võrrandisüsteemidele kujul $F(x) = 0$. Siin

$F(X) = (f_1(x), f_2(x), \dots, f_m(x))$ on vektorfunktsioon ning otsitavate vektor on $x = (x_1, x_2, \dots, x_m)$.

Newtoni meetodi algoritm

$$x^n = x^{n-1} - [F'(x^{n-1})]^{-1} F(x^{n-1}),$$

kus $x^{n-1} = (x_1^{n-1}, x_2^{n-1}, \dots, x_m^{n-1})$ ja $x^n = (x_1^n, x_2^n, \dots, x_m^n)$ on kaks järjestikust lähendit.

Newtoni meetod

Võrrandi $f(x) = 0$ korral oli Newtoni meetodi eeskiri

$$x_n = x_{n-1} - \frac{f(x_{n-1})}{f'(x_{n-1})}.$$

Seda meetodit saab üldistada ka mittelineaarsetele võrrandisüsteemidele kujul $F(x) = 0$. Siin

$F(X) = (f_1(x), f_2(x), \dots, f_m(x))$ on vektorfunktsioon ning otsitavate vektor on $x = (x_1, x_2, \dots, x_m)$.

Newtoni meetodi algoritm

$$x^n = x^{n-1} - [F'(x^{n-1})]^{-1} F(x^{n-1}),$$

kus $x^{n-1} = (x_1^{n-1}, x_2^{n-1}, \dots, x_m^{n-1})$ ja $x^n = (x_1^n, x_2^n, \dots, x_m^n)$ on kaks järjestikust lähendit.

Newtoni meetod

Võrrandi $f(x) = 0$ korral oli Newtoni meetodi eeskiri

$$x_n = x_{n-1} - \frac{f(x_{n-1})}{f'(x_{n-1})}.$$

Seda meetodit saab üldistada ka mittelineaarsetele võrrandisüsteemidele kujul $F(x) = 0$. Siin

$F(X) = (f_1(x), f_2(x), \dots, f_m(x))$ on vektorfunktsioon ning otsitavate vektor on $x = (x_1, x_2, \dots, x_m)$.

Newtoni meetodi algoritm

$$x^n = x^{n-1} - [F'(x^{n-1})]^{-1} F(x^{n-1}),$$

kus $x^{n-1} = (x_1^{n-1}, x_2^{n-1}, \dots, x_m^{n-1})$ ja $x^n = (x_1^n, x_2^n, \dots, x_m^n)$ on kaks järjestikust lähendit.

Newtoni meetod on ruutkoonduvusega, st

$$\|x^n - x^*\| \leq C \|x^{n-1} - x^*\|^2.$$

Modifitseeritud Newtoni meetod

$$x^n = x^{n-1} - [F'(x^0)]^{-1} F(x^{n-1})$$

Meetod koondub geomeetrilise progressiooni kiirusega.

Newtoni meetod on ruutkoonduvusega, st

$$\|x^n - x^*\| \leq C \|x^{n-1} - x^*\|^2.$$

Modifitseeritud Newtoni meetod

$$x^n = x^{n-1} - [F'(x^0)]^{-1} F(x^{n-1})$$

Meetod koondub geomeetrilise progressiooni kiirusega.

Ekstreemumülesannete lahendamine

Vaatame m -muutuja funktsioon $f(x)$, mille argumendiks on $x = (x_1; x_2; \dots; x_m)$ ning vaja on leida selle funktsiooni maksimum või miinimum. Funktsiooni miinimumi leidmiseks saab kasutada iteratiivseid meetodeid, mille korral liigutakse järk-järgult miinimumpunkti poole funktsiooni kahanemise suunas. Olgu algähend $x^0 = (x_1^0; x_2^0; \dots; x_m^0) \in R^m$ ja arvutame funktsiooni $f(x)$ gradiendi punktis x^0 :

$$v^0 = \text{grad}f(x^0) = \left(\frac{\partial}{\partial x_1} f(x^0); \dots; \frac{\partial}{\partial x_m} f(x^0) \right).$$

Ekstreemumülesannete lahendamine

Vaatame m -muutuja funktsioon $f(x)$, mille argumendiks on $x = (x_1; x_2; \dots; x_m)$ ning vaja on leida selle funktsiooni maksimum või miinimum. Funktsiooni miinimumi leidmiseks saab kasutada iteratiivseid meetodeid, mille korral liigutakse järk-järgult miinimumpunkti poole funktsiooni kahanemise suunas. Olgu algähend $x^0 = (x_1^0; x_2^0; \dots; x_m^0) \in R^m$ ja arvutame funktsiooni $f(x)$ gradiendi punktis x^0 :

$$v^0 = \text{grad}f(x^0) = \left(\frac{\partial}{\partial x_1} f(x^0); \dots; \frac{\partial}{\partial x_m} f(x^0) \right).$$

Ekstreemumülesannete lahendamine

Vaatame m -muutuja funktsioon $f(x)$, mille argumendiks on $x = (x_1; x_2; \dots; x_m)$ ning vaja on leida selle funktsiooni maksimum või miinimum. Funktsiooni miinimumi leidmiseks saab kasutada iteratiivseid meetodeid, mille korral liigutakse järk-järgult miinimumpunkti poole funktsiooni kahanemise suunas. Olgu algähend $x^0 = (x_1^0; x_2^0; \dots; x_m^0) \in R^m$ ja arvutame funktsiooni $f(x)$ gradiendi punktis x^0 :

$$v^0 = \text{grad}f(x^0) = \left(\frac{\partial}{\partial x_1} f(x^0); \dots; \frac{\partial}{\partial x_m} f(x^0) \right).$$

Antigradient ehk vektor $-v^0$ määrab suuna, milles funktsioon $f(x)$ kahaneb kõige kiiremini punktist x^0 lähtudes. Sellest tulenevalt leiame uue lähendi x^1 selliselt, et liigume punktist x^0 teatud sammu võrra vektori $-v^0$ suunas, st arvutame $x^1 = x^0 - t_0 v^0$. Arv t_0 on sammu pikkus, mis tuleb valida selliselt, et funktsioon f kahaneks, st kehtiks võrratus $f(x^1) < f(x^0)$. Punktist x^1 liigume edasi analoogiliselt. Sellist eeskirja kasutavaid meetodeid nimetatakse **gradientmeetoditeks**. Optimaalne sammu pikkus t_{n-1} on selline, mille korral funktsioon $f(x)$ on punktist x^{n-1} lähtuval antigradiendi $-v^{n-1}$ suunal minimaalne. Selleks tuleb valida t_{n-1} nii, et ühe muutuja t funktsioon $f(x^{n-1} - tv^{n-1})$ saavutaks miinimumi punktis $t = t_{n-1}$. Kui gradientmeetodis on sammu pikkus valitud sellise eeskirja kohaselt, siis nimetatakse seda meetodit **kiireima languse meetodiks**. Seega tuleb kiireima languse meetodis n -ndal sammul lahendada ühe muutuja funktsiooni miinimumülesanne

$$f(x^{n-1} - t_{n-1}v^{n-1}) = \min_{t \in \mathbb{R}} f(x^{n-1} - tv^{n-1}).$$

Antigradiend ehk vektor $-v^0$ määrab suuna, milles funktsioon $f(x)$ kahaneb kõige kiiremini punktist x^0 lähtudes. Sellest tulenevalt leiame uue lähendi x^1 selliselt, et liigume punktist x^0 teatud sammu võrra vektori $-v^0$ suunas, st arvutame $x^1 = x^0 - t_0 v^0$. Arv t_0 on sammu pikkus, mis tuleb valida selliselt, et funktsioon f kahaneks, st kehtiks võrratus $f(x^1) < f(x^0)$. Punktist x^1 liigume edasi analoogiliselt. Sellist eeskirja kasutavaid meetodeid nimetatakse **gradientmeetoditeks**.

Optimaalne sammu pikkus t_{n-1} on selline, mille korral funktsioon $f(x)$ on punktist x^{n-1} lähtuval antigradiendi $-v^{n-1}$ suunal minimaalne. Selleks tuleb valida t_{n-1} nii, et ühe muutuja t funktsioon $f(x^{n-1} - tv^{n-1})$ saavutaks miinimumi punktis $t = t_{n-1}$. Kui gradientmeetodis on sammu pikkus valitud sellise eeskirja kohaselt, siis nimetatakse seda meetodit **kiireima languse meetodiks**. Seega tuleb kiireima languse meetodis n -ndal sammul lahendada ühe muutuja funktsiooni miinimumülesanne

$$f(x^{n-1} - t_{n-1}v^{n-1}) = \min_{t \in \mathbb{R}} f(x^{n-1} - tv^{n-1}).$$

Antigradiend ehk vektor $-v^0$ määrab suuna, milles funktsioon $f(x)$ kahaneb kõige kiiremini punktist x^0 lähtudes. Sellest tulenevalt leiame uue lähendi x^1 selliselt, et liigume punktist x^0 teatud sammu võrra vektori $-v^0$ suunas, st arvutame $x^1 = x^0 - t_0 v^0$. Arv t_0 on sammu pikkus, mis tuleb valida selliselt, et funktsioon f kahaneks, st kehtiks võrratus $f(x^1) < f(x^0)$. Punktist x^1 liigume edasi analoogiliselt. Sellist eeskirja kasutavaid meetodeid nimetatakse **gradientmeetoditeks**.

Optimaalne sammu pikkus t_{n-1} on selline, mille korral funktsioon $f(x)$ on punktist x^{n-1} lähtuval antigradiendi $-v^{n-1}$ suunal minimaalne. Selleks tuleb valida t_{n-1} nii, et ühe muutuja t funktsioon $f(x^{n-1} - tv^{n-1})$ saavutaks miinimumi punktis $t = t_{n-1}$. Kui gradientmeetodis on sammu pikkus valitud sellise eeskirja kohaselt, siis nimetatakse seda meetodit **kiireima languse meetodiks**. Seega tuleb kiireima languse meetodis n -ndal sammul lahendada ühe muutuja funktsiooni miinimumülesanne

$$f(x^{n-1} - t_{n-1}v^{n-1}) = \min_{t \in \mathbb{R}} f(x^{n-1} - tv^{n-1}).$$

Antigradiend ehk vektor $-v^0$ määrab suuna, milles funktsioon $f(x)$ kahaneb kõige kiiremini punktist x^0 lähtudes. Sellest tulenevalt leiame uue lähendi x^1 selliselt, et liigume punktist x^0 teatud sammu võrra vektori $-v^0$ suunas, st arvutame $x^1 = x^0 - t_0 v^0$. Arv t_0 on sammu pikkus, mis tuleb valida selliselt, et funktsioon f kahaneks, st kehtiks võrratus $f(x^1) < f(x^0)$. Punktist x^1 liigume edasi analoogiliselt. Sellist eeskirja kasutavaid meetodeid nimetatakse **gradientmeetoditeks**. Optimaalne sammu pikkus t_{n-1} on selline, mille korral funktsioon $f(x)$ on punktist x^{n-1} lähtuval antigradiendi $-v^{n-1}$ suunal minimaalne. Selleks tuleb valida t_{n-1} nii, et ühe muutuja t funktsioon $f(x^{n-1} - tv^{n-1})$ saavutaks miinimumi punktis $t = t_{n-1}$. Kui gradientmeetodis on sammu pikkus valitud sellise eeskirja kohaselt, siis nimetatakse seda meetodit **kiireima languse meetodiks**. Seega tuleb kiireima languse meetodis n -ndal sammul lahendada ühe muutuja funktsiooni miinimumülesanne

$$f(x^{n-1} - t_{n-1}v^{n-1}) = \min_{t \in \mathbb{R}} f(x^{n-1} - tv^{n-1}).$$

Kiireima languse meetod ruutfunktsiooni korral

Olgu $f(x)$ ruutfunktsioon, st

$$f(x) = \sum_{i,j=1}^m \alpha_{ij} x_i x_j + \sum_{i=1}^m \beta_i x_i + \gamma,$$

kus $\alpha_{i,j}$, β_i ja γ on konstandid.

Olgu

$$A = \begin{pmatrix} \alpha_{11} & \alpha_{12} & \dots & \alpha_{1m} \\ \alpha_{21} & \alpha_{22} & \dots & \alpha_{2m} \\ \dots & \dots & \dots & \dots \\ \alpha_{m1} & \alpha_{m2} & \dots & \alpha_{mm} \end{pmatrix}$$

sümmeetriline, st $\alpha_{ij} = \alpha_{ji}$.

Ruutfunktsiooni saab lühemalt kirjutada kujule

$$f(x) = Ax \cdot x + \beta \cdot x + \gamma.$$

Kiireima languse meetod ruutfunktsiooni korral

Olgu $f(x)$ ruutfunktsioon, st

$$f(x) = \sum_{i,j=1}^m \alpha_{ij} x_i x_j + \sum_{i=1}^m \beta_i x_i + \gamma,$$

kus $\alpha_{i,j}$, β_i ja γ on konstandid.

Olgu

$$A = \begin{pmatrix} \alpha_{11} & \alpha_{12} & \dots & \alpha_{1m} \\ \alpha_{21} & \alpha_{22} & \dots & \alpha_{2m} \\ \dots & \dots & \dots & \dots \\ \alpha_{m1} & \alpha_{m2} & \dots & \alpha_{mm} \end{pmatrix}$$

sümmeetriline, st $\alpha_{ij} = \alpha_{ji}$.

Ruutfunktsiooni saab lühemalt kirjutada kujule

$$f(x) = Ax \cdot x + \beta \cdot x + \gamma.$$

Kiireima languse meetod ruutfunktsiooni korral

Olgu $f(x)$ ruutfunktsioon, st

$$f(x) = \sum_{i,j=1}^m \alpha_{ij} x_i x_j + \sum_{i=1}^m \beta_i x_i + \gamma,$$

kus $\alpha_{i,j}$, β_i ja γ on konstandid.

Olgu

$$A = \begin{pmatrix} \alpha_{11} & \alpha_{12} & \dots & \alpha_{1m} \\ \alpha_{21} & \alpha_{22} & \dots & \alpha_{2m} \\ \dots & \dots & \dots & \dots \\ \alpha_{m1} & \alpha_{m2} & \dots & \alpha_{mm} \end{pmatrix}$$

sümmeetriline, st $\alpha_{ij} = \alpha_{ji}$.

Ruutfunktsiooni saab lühemalt kirjutada kujule

$$f(x) = Ax \cdot x + \beta \cdot x + \gamma.$$

Kiireima languse meetod ruutfunktsiooni korral

Olgu $f(x)$ ruutfunktsioon, st

$$f(x) = \sum_{i,j=1}^m \alpha_{ij} x_i x_j + \sum_{i=1}^m \beta_i x_i + \gamma,$$

kus $\alpha_{i,j}$, β_i ja γ on konstandid.

Olgu

$$A = \begin{pmatrix} \alpha_{11} & \alpha_{12} & \dots & \alpha_{1m} \\ \alpha_{21} & \alpha_{22} & \dots & \alpha_{2m} \\ \dots & \dots & \dots & \dots \\ \alpha_{m1} & \alpha_{m2} & \dots & \alpha_{mm} \end{pmatrix}$$

sümmeetriline, st $\alpha_{ij} = \alpha_{ji}$.

Ruutfunktsiooni saab lühemalt kirjutada kujule

$$f(x) = Ax \cdot x + \beta \cdot x + \gamma.$$

Miinimumi leidumiseks

$$Ax \cdot x > 0 \quad \forall x \neq 0.$$

Leiame osatuletised

$$\begin{aligned} \frac{\partial}{\partial x_k} f(x) &= \frac{\partial}{\partial x_k} [Ax \cdot x + \beta \cdot x + \gamma] = \\ &= \sum_{i,j=1}^m \alpha_{i,j} \frac{\partial x_i}{\partial x_k} x_j + \sum_{i,j=1}^m \alpha_{i,j} x_i \frac{\partial x_j}{\partial x_k} + \sum_{i=1}^m \beta_i \frac{\partial x_i}{\partial x_k} = \\ &= \sum_{j=1}^m \alpha_{k,j} x_j + \sum_{i=1}^m \alpha_{i,j} x_i + \beta_k = \sum_{i=1}^m (\alpha_{k,i} + \alpha_{i,k}) x_i + \beta_k. \end{aligned}$$

Miinimumi leidumiseks

$$Ax \cdot x > 0 \quad \forall x \neq 0.$$

Leiame osatuletised

$$\begin{aligned} \frac{\partial}{\partial x_k} f(x) &= \frac{\partial}{\partial x_k} [Ax \cdot x + \beta \cdot x + \gamma] = \\ &= \sum_{i,j=1}^m \alpha_{i,j} \frac{\partial x_i}{\partial x_k} x_j + \sum_{i,j=1}^m \alpha_{i,j} x_i \frac{\partial x_j}{\partial x_k} + \sum_{i=1}^m \beta_i \frac{\partial x_i}{\partial x_k} = \\ &= \sum_{j=1}^m \alpha_{k,j} x_j + \sum_{i=1}^m \alpha_{i,j} x_i + \beta_k = \sum_{i=1}^m (\alpha_{k,i} + \alpha_{i,k}) x_i + \beta_k. \end{aligned}$$

Miinimumi leidumiseks

$$Ax \cdot x > 0 \quad \forall x \neq 0.$$

Leiame osatuletised

$$\begin{aligned} \frac{\partial}{\partial x_k} f(x) &= \frac{\partial}{\partial x_k} [Ax \cdot x + \beta \cdot x + \gamma] = \\ &= \sum_{i,j=1}^m \alpha_{i,j} \frac{\partial x_i}{\partial x_k} x_j + \sum_{i,j=1}^m \alpha_{i,j} x_i \frac{\partial x_j}{\partial x_k} + \sum_{i=1}^m \beta_i \frac{\partial x_i}{\partial x_k} = \\ &= \sum_{j=1}^m \alpha_{k,j} x_j + \sum_{i=1}^m \alpha_{i,k} x_i + \beta_k = \sum_{i=1}^m (\alpha_{k,i} + \alpha_{i,k}) x_i + \beta_k. \end{aligned}$$

Miinimumi leidumiseks

$$Ax \cdot x > 0 \quad \forall x \neq 0.$$

Leiame osatuletised

$$\begin{aligned} \frac{\partial}{\partial x_k} f(x) &= \frac{\partial}{\partial x_k} [Ax \cdot x + \beta \cdot x + \gamma] = \\ &= \sum_{i,j=1}^m \alpha_{i,j} \frac{\partial x_i}{\partial x_k} x_j + \sum_{i,j=1}^m \alpha_{i,j} x_i \frac{\partial x_j}{\partial x_k} + \sum_{i=1}^m \beta_i \frac{\partial x_i}{\partial x_k} = \\ &= \sum_{j=1}^m \alpha_{k,j} x_j + \sum_{i=1}^m \alpha_{i,j} x_i + \beta_k = \sum_{i=1}^m (\alpha_{k,i} + \alpha_{i,k}) x_i + \beta_k. \end{aligned}$$

Miinimumi leidumiseks

$$Ax \cdot x > 0 \quad \forall x \neq 0.$$

Leiame osatuletised

$$\begin{aligned} \frac{\partial}{\partial x_k} f(x) &= \frac{\partial}{\partial x_k} [Ax \cdot x + \beta \cdot x + \gamma] = \\ &= \sum_{i,j=1}^m \alpha_{i,j} \frac{\partial x_i}{\partial x_k} x_j + \sum_{i,j=1}^m \alpha_{i,j} x_i \frac{\partial x_j}{\partial x_k} + \sum_{i=1}^m \beta_i \frac{\partial x_i}{\partial x_k} = \\ &= \sum_{j=1}^m \alpha_{k,j} x_j + \sum_{i=1}^m \alpha_{i,k} x_i + \beta_k = \sum_{i=1}^m (\alpha_{k,i} + \alpha_{i,k}) x_i + \beta_k. \end{aligned}$$

Miinimumi leidumiseks

$$Ax \cdot x > 0 \quad \forall x \neq 0.$$

Leiame osatuletised

$$\begin{aligned} \frac{\partial}{\partial x_k} f(x) &= \frac{\partial}{\partial x_k} [Ax \cdot x + \beta \cdot x + \gamma] = \\ &= \sum_{i,j=1}^m \alpha_{i,j} \frac{\partial x_i}{\partial x_k} x_j + \sum_{i,j=1}^m \alpha_{i,j} x_i \frac{\partial x_j}{\partial x_k} + \sum_{i=1}^m \beta_i \frac{\partial x_i}{\partial x_k} = \\ &= \sum_{j=1}^m \alpha_{k,j} x_j + \sum_{i=1}^m \alpha_{i,k} x_i + \beta_k = \sum_{i=1}^m (\alpha_{k,i} + \alpha_{i,k}) x_i + \beta_k. \end{aligned}$$

Sümmeetrilisusest $\alpha_{k,j} + \alpha_{i,k} = \alpha_{k,i} + \alpha_{k,i} = 2\alpha_{k,i}$. Seega

$$\frac{\partial}{\partial x_k} f(x) = 2 \sum_{i=1}^m \alpha_{k,i} x_i + \beta_k.$$

Järelikult

$$\text{grad}f(x) = 2Ax + \beta$$

ning

$$v^{n-1} = \text{grad}f(x^{n-1}) = 2Ax^{n-1} + \beta.$$

Määrame ka sammu pikkuse t . Selleks

$$f(x^{n-1} - tv^{n-1}) = A(x^{n-1} - tv^{n-1}) \cdot (x^{n-1} - tv^{n-1}) + \beta \cdot (x^{n-1} - tv^{n-1}) + \gamma.$$

Leiame tuletise muutuja t suhtes

Sümmeetrilisusest $\alpha_{k,i} + \alpha_{i,k} = \alpha_{k,i} + \alpha_{k,i} = 2\alpha_{k,i}$. Seega

$$\frac{\partial}{\partial x_k} f(x) = 2 \sum_{i=1}^m \alpha_{k,i} x_i + \beta_k.$$

Järelikult

$$\text{grad}f(x) = 2Ax + \beta$$

ning

$$v^{n-1} = \text{grad}f(x^{n-1}) = 2Ax^{n-1} + \beta.$$

Määrame ka sammu pikkuse t . Selleks

$$f(x^{n-1} - tv^{n-1}) = A(x^{n-1} - tv^{n-1}) \cdot (x^{n-1} - tv^{n-1}) + \beta \cdot (x^{n-1} - tv^{n-1}) + \gamma.$$

Leiame tuletise muutuja t suhtes

Sümmeetrilisusest $\alpha_{k,i} + \alpha_{i,k} = \alpha_{k,i} + \alpha_{k,i} = 2\alpha_{k,i}$. Seega

$$\frac{\partial}{\partial x_k} f(x) = 2 \sum_{i=1}^m \alpha_{k,i} x_i + \beta_k.$$

Järelikult

$$\text{grad} f(x) = 2Ax + \beta$$

ning

$$v^{n-1} = \text{grad} f(x^{n-1}) = 2Ax^{n-1} + \beta.$$

Määrame ka sammu pikkuse t . Selleks

$$f(x^{n-1} - tv^{n-1}) = A(x^{n-1} - tv^{n-1}) \cdot (x^{n-1} - tv^{n-1}) + \beta \cdot (x^{n-1} - tv^{n-1}) + \gamma.$$

Leiame tuletise muutuja t suhtes

Sümmeetrilisusest $\alpha_{k,i} + \alpha_{i,k} = \alpha_{k,i} + \alpha_{k,i} = 2\alpha_{k,i}$. Seega

$$\frac{\partial}{\partial x_k} f(x) = 2 \sum_{i=1}^m \alpha_{k,i} x_i + \beta_k.$$

Järelikult

$$\text{grad} f(x) = 2Ax + \beta$$

ning

$$v^{n-1} = \text{grad} f(x^{n-1}) = 2Ax^{n-1} + \beta.$$

Määrame ka sammu pikkuse t . Selleks

$$f(x^{n-1} - tv^{n-1}) = A(x^{n-1} - tv^{n-1}) \cdot (x^{n-1} - tv^{n-1}) + \beta \cdot (x^{n-1} - tv^{n-1}) + \gamma.$$

Leiame tuletise muutuja t suhtes

Sümmeetrilisusest $\alpha_{k,i} + \alpha_{i,k} = \alpha_{k,i} + \alpha_{k,i} = 2\alpha_{k,i}$. Seega

$$\frac{\partial}{\partial x_k} f(x) = 2 \sum_{i=1}^m \alpha_{k,i} x_i + \beta_k.$$

Järelikult

$$\text{grad}f(x) = 2Ax + \beta$$

ning

$$v^{n-1} = \text{grad}f(x^{n-1}) = 2Ax^{n-1} + \beta.$$

Määrame ka sammu pikkuse t . Selleks

$$f(x^{n-1} - tv^{n-1}) = A(x^{n-1} - tv^{n-1}) \cdot (x^{n-1} - tv^{n-1}) + \beta \cdot (x^{n-1} - tv^{n-1}) + \gamma.$$

Leiame tuletise muutuja t suhtes

Sümmeetrilisusest $\alpha_{k,i} + \alpha_{i,k} = \alpha_{k,i} + \alpha_{k,i} = 2\alpha_{k,i}$. Seega

$$\frac{\partial}{\partial x_k} f(x) = 2 \sum_{i=1}^m \alpha_{k,i} x_i + \beta_k.$$

Järelikult

$$\text{grad}f(x) = 2Ax + \beta$$

ning

$$v^{n-1} = \text{grad}f(x^{n-1}) = 2Ax^{n-1} + \beta.$$

Määrame ka sammu pikkuse t . Selleks

$$f(x^{n-1} - tv^{n-1}) = A(x^{n-1} - tv^{n-1}) \cdot (x^{n-1} - tv^{n-1}) + \beta \cdot (x^{n-1} - tv^{n-1}) + \gamma.$$

Leiame tuletise muutuja t suhtes

$$\frac{d}{dt}f(x^{n-1} - tv^{n-1}) = -Av^{n-1} \cdot x^{n-1} - Ax^{n-1} \cdot v^{n-1} + 2tAv^{n-1} \cdot v^{n-1} - \beta \cdot v^{n-1}.$$

Teadupärast saab seosest $\frac{d}{dt}f(x^{n-1} - tv^{n-1}) = 0$ määrata optimaalse sammu pikkuse

$$t_{n-1} = \frac{Av^{n-1} \cdot x^{n-1} + Ax^{n-1} \cdot v^{n-1} + \beta \cdot v^{n-1}}{2Av^{n-1} \cdot v^{n-1}}.$$

$$\frac{d}{dt}f(x^{n-1} - tv^{n-1}) = -Av^{n-1} \cdot x^{n-1} - Ax^{n-1} \cdot v^{n-1} + 2tAv^{n-1} \cdot v^{n-1} - \beta \cdot v^{n-1}.$$

Teadupärast saab seosest $\frac{d}{dt}f(x^{n-1} - tv^{n-1}) = 0$ määrata optimaalse sammu pikkuse

$$t_{n-1} = \frac{Av^{n-1} \cdot x^{n-1} + Ax^{n-1} \cdot v^{n-1} + \beta \cdot v^{n-1}}{2Av^{n-1} \cdot v^{n-1}}.$$

$$\frac{d}{dt}f(x^{n-1} - tv^{n-1}) = -Av^{n-1} \cdot x^{n-1} - Ax^{n-1} \cdot v^{n-1} + 2tAv^{n-1} \cdot v^{n-1} - \beta \cdot v^{n-1}.$$

Teadupärast saab seosest $\frac{d}{dt}f(x^{n-1} - tv^{n-1}) = 0$ määrata optimaalse sammu pikkuse

$$t_{n-1} = \frac{Av^{n-1} \cdot x^{n-1} + Ax^{n-1} \cdot v^{n-1} + \beta \cdot v^{n-1}}{2Av^{n-1} \cdot v^{n-1}}.$$