

# 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  $x^0$ :

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

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 miinumülesanne

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

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 miinumülesanne

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

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 miinumülesanne

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



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  $\alpha_{i,j}$ ,  $\beta_i$  ja  $\gamma$  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  $\alpha_{i,j}$ ,  $\beta_i$  ja  $\gamma$  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  $\alpha_{i,j}$ ,  $\beta_i$  ja  $\gamma$  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  $\alpha_{i,j}$ ,  $\beta_i$  ja  $\gamma$  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

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

## Miimumi leidumiseks

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

## Leiame osatuletised

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



## Miimumi leidumiseks

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

Leiame osatuletised

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

## Miimumi leidumiseks

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

Leiame osatuletised

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

## Miimumi leidumiseks

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

Leiame osatuletised

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

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

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