

Gradient ja Hessiaan

Konstantin Tretjakov

1 Gradient

Definitsioon Olgu $f : \mathbb{R}^n \rightarrow \mathbb{R}^m$. Funktsiooni f nimetatakse diferentseeruvaks punktis \mathbf{x}_0 , kui leidub lineaarteisendus $\mathbf{A}(\mathbf{x}_0)$ selline, et

$$f(\mathbf{x}_0 + \Delta\mathbf{x}) = f(\mathbf{x}_0) + \mathbf{A}(\mathbf{x}_0)\Delta\mathbf{x} + o(\Delta\mathbf{x})$$

Funktsiooni f nimetatakse diferentseeruvaks hulgal $Q \subset \mathbb{R}^n$, kui ta on diferentseeruv igas hulga Q punktis. Kui f on diferentseeruv hulgal \mathbb{R}^n , siis ütleme lihtsalt, et f on diferentseeruv. Maatriksit $\mathbf{A}(\mathbf{x}_0)$ nimetatakse funktsiooni f *tuletiseks* või *Jakobi maatriksiks* (punktis \mathbf{x}_0) ning tähistatakse $\frac{\partial f(\mathbf{x}_0)}{\partial \mathbf{x}}$ või $f'(\mathbf{x}_0)$.

Ülesanne: Mida tähendab eeltoodud definitsioonis $o(\Delta\mathbf{x})$ ja miks pole see $o(\|\Delta\mathbf{x}\|)$?

Teoreem 1.1

$$(\mathbf{A}(\mathbf{x}_0))_{ij} = \frac{\partial f_i(\mathbf{x}_0)}{\partial x_j}$$

Ülesanne*: Tõesta seda.

Vihje: alguses vaatle juhtu $f : \mathbb{R}^n \rightarrow \mathbb{R}$ ning kasuta täisdiferentsiaali valemit $df(\mathbf{x}) = \sum_{i=1}^n \frac{\partial f}{\partial x_i} dx_i$

Teoreem 1.2

$$(f(g(\mathbf{x})))' = f'(g(\mathbf{x}))g'(\mathbf{x})$$

Ülesanne*: Tõesta seda.

Vihje: alguses vaatle juhtu $f : \mathbb{R}^n \rightarrow \mathbb{R}$ ning kasuta valemit $\frac{\partial f \circ g}{\partial x_j}(\mathbf{x}) = \sum_{i=1}^n \frac{\partial f}{\partial x_i}(g(\mathbf{x})) \cdot \frac{\partial g_i}{\partial x_j}(\mathbf{x})$.

Olgu $f : \mathbb{R}^n \rightarrow \mathbb{R}$ diferentseeruv funktsioon. Tema tuletis (punktis \mathbf{x}_0) on siis $1 \times n$ maatriks

$$\mathbf{A}(\mathbf{x}_0) = \begin{pmatrix} \frac{\partial f(\mathbf{x}_0)}{\partial x_1} & \frac{\partial f(\mathbf{x}_0)}{\partial x_2} & \dots & \frac{\partial f(\mathbf{x}_0)}{\partial x_n} \end{pmatrix}$$

Vektorit $\mathbf{A}(\mathbf{x}_0)^T$ nimetatakse funktsiooni f *gradiendiks* ning tähistatakse $\text{grad}_{\mathbf{x}} f(\mathbf{x}_0)$ või $\nabla_{\mathbf{x}} f(\mathbf{x}_0)$ või lihtsalt $\nabla f(\mathbf{x}_0)$.

Teoreem 1.3

$$\begin{aligned} \nabla(f(\mathbf{x})g(\mathbf{x})) &= \nabla f(\mathbf{x})g(\mathbf{x}) + f(\mathbf{x})\nabla g(\mathbf{x}) \\ \nabla(f(\mathbf{x})/g(\mathbf{x})) &= (\nabla f(\mathbf{x})g(\mathbf{x}) - f(\mathbf{x})\nabla g(\mathbf{x}))/g^2(\mathbf{x}) \\ \nabla(f(g(\mathbf{x}))) &= \nabla f(g(\mathbf{x}))\nabla g(\mathbf{x}) = f'(g(\mathbf{x}))\nabla g(\mathbf{x}) \end{aligned}$$

Ülesanne: Veendu valemite õigsuses.

Vihje: kasuta teoreeme (1.1) ja (1.2).

Ülesanne*: Veendu, et gradiendi saab vaadelda kui vektorit, mis näitab funktsiooni pinnal suurima tõusu poole.

Näited

$$\frac{\partial \mathbf{a}^T \mathbf{x}}{\partial \mathbf{x}} = \mathbf{a}^T$$
$$\frac{\partial \mathbf{x}^T \mathbf{A} \mathbf{x}}{\partial \mathbf{x}} = \mathbf{x}^T (\mathbf{A} + \mathbf{A}^T)$$

Ülesanne: Veendu valemite õigsuses.

2 Hessiaan

Definitsioon Olgu $f : \mathbb{R}^n \rightarrow \mathbb{R}$ diferentseeruv ja $\nabla f : \mathbb{R}^n \rightarrow \mathbb{R}^n$ diferentseeruv (s.t. f on kaks korda diferentseeruv). Funktsiooni ∇f tuletis punktis \mathbf{x}_0 on $n \times n$ maatriks $\mathbf{H}(\mathbf{x}_0)$, mida nimetatakse funktsiooni f teiseks tuletiseks ehk Hessiaaniks (punktis \mathbf{x}_0) ja tähistatakse $\frac{\partial^2 f(\mathbf{x}_0)}{\partial^2 \mathbf{x}}$ või $\nabla^2 f(\mathbf{x}_0)$.

Teoreem 2.1

$$(\mathbf{H}(\mathbf{x}_0))_{ij} = \frac{\partial^2 f(\mathbf{x}_0)}{\partial x_i \partial x_j}$$

Ülesanne: Tõesta seda.

Vihje: väide järeldub teoreemist (1.1).

Teoreem 2.2 Kui funktsiooni f osatuletised $\frac{\partial^2 f}{\partial x_i \partial x_j}$, $\frac{\partial^2 f}{\partial x_j \partial x_i}$ on pidevad punktis \mathbf{x}_0 , siis nad on võrdsed selles punktis.

Seega piisavalt sileda funktsiooni Hessiaan on sümmeetriline maatriks.

Teoreem 2.3 Sümmeetrilise maatriksi kõik omaväärtused on reaalarvud.

Teoreem 2.4 Sümmeetrilise maatriksi omavektoritest saab koostada ortonormeeritud baasi.

Ülesanne*: Leia mõnest õpikust nende teoreemide tõestusi ja saa nendest aru (vt. näiteks M. Kilp. *Algebra I*).

Lõpuks üks tähtsamaid tulemusi: kui funktsioon on kaks korda diferentseeruv, me saame arendada teda Taylor'i ritta:

Teoreem 2.5

$$f(\mathbf{x}_0 + \Delta \mathbf{x}) = f(\mathbf{x}_0) + \frac{\partial f(\mathbf{x}_0)}{\partial \mathbf{x}} \Delta \mathbf{x} + \frac{1}{2} \Delta \mathbf{x}^T \left(\frac{\partial^2 f(\mathbf{x}_0)}{\partial^2 \mathbf{x}} \right) \Delta \mathbf{x} + o(\|\Delta \mathbf{x}\|^2)$$

Ülesanne: Tõesta seda.

Vihje: vaja on rakendada diferentseeruvuse definitsiooni kaks korda.

Viimane teoreem väidab, et kui meil on mingi piisavalt sile funktsioon, ning me vaatleme teda ainult mingi punkti \mathbf{x} väikeses ümbruses, me saame asendada teda ruutfunktsiooniga. Seega on kasuks kujutada ette kuidas näeb välja funktsioon kujul $f(\mathbf{x}) = c + \mathbf{a}^T \mathbf{x} + \mathbf{x}^T \mathbf{H} \mathbf{x}$, kus \mathbf{H} on sümmeetriline maatriks.

Ülesanne: Vaatleme alguses funktsiooni $f(\mathbf{x}) = \mathbf{x}^T \mathbf{H} \mathbf{x}$, kus $\mathbf{x} \in \mathbb{R}^2$ ning \mathbf{H} on sümmeetriline maatriks. Olgu maatriksi \mathbf{H} ortogonaalsed ühikupikkusega omavektorid \mathbf{v}_1 ja \mathbf{v}_2 ning vastavad omaväärtused λ_1 ja λ_2 . Joonista tasandile vektorid \mathbf{v}_1 ja \mathbf{v}_2 . Uuri kuidas funktsioon käitub nende vektorite poolt määratud sirgete peal, s.t. mis on funktsiooni väärtused punktides $t\mathbf{v}_1$, $t\mathbf{v}_2$ ($t \in \mathbb{R}$). Kas näed, et f on sisuliselt kas kumer paraboloid, või "sadulpunktiga" pind? Mis on arvude λ_i roll?

Ülesanne: Analüüsi kuidas peab välja nägema funktsioon $f(\mathbf{x}) = c + \mathbf{a}^T \mathbf{x} + \mathbf{x}^T \mathbf{H} \mathbf{x}$.

3 Lokaalse miinimumi mõiste

Tähistagu f funktsiooni $\mathbb{R}^n \rightarrow \mathbb{R}$.

Definitsioon Punkt \mathbf{x}^* on funktsiooni f *lokaalne miinimum* (või lihtsalt miinimum), kui leidub selle punkti ümbrus $U(\mathbf{x}^*)$ niisugune, et $f(\mathbf{x}) \geq f(\mathbf{x}^*) \quad \forall \mathbf{x} \in U(\mathbf{x}^*)$.

Teoreem 3.1 (Fermat) *Olgu \mathbf{x}^* funktsiooni f miinimumi punkt ning f on diferentseeruv selles punktis. Siis $\nabla f(\mathbf{x}^*) = \mathbf{0}$.*

Ülesanne: Tõesta seda.

Üldiselt vastupidine väide ei kehti, s. t. gradiendi võrdus nulliga ei ole miinimumi piisav tingimus. Kehtivad aga järgmised väited:

Teoreem 3.2 *Kui f on kumer funktsioon, s.t.*

$$\forall \mathbf{x}, \mathbf{y} \quad f(\lambda \mathbf{x} + (1 - \lambda)\mathbf{y}) \leq \lambda f(\mathbf{x}) + (1 - \lambda)f(\mathbf{y})$$

siis tingimus $\nabla f(\mathbf{x}^) = \mathbf{0}$ on samaväärne sellega, et \mathbf{x}^* on funktsiooni f globaalne miinimum.*

Teoreem 3.3 *Olgu \mathbf{x}^* funktsiooni f miinimumi punkt, ning f on kaks korda diferentseeruv punktis \mathbf{x}^* . Siis $\nabla^2 f(\mathbf{x}^*) \geq 0$ (s.t. funktsiooni Hessiaan on mittenegatiivselt määratud selles punktis).*

Teoreem 3.4 *Kui f on kaks korda diferentseeruv punktis \mathbf{x}^* , $\nabla f(\mathbf{x}^*) = \mathbf{0}$ ning $\nabla^2 f(\mathbf{x}^*) > 0$, siis \mathbf{x}^* on funktsiooni f miinimum.*

Ülesanne: Sõnasta eelmiste kahe väidete erijuhud funktsiooni $f : \mathbb{R} \rightarrow \mathbb{R}$ jaoks.