

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ



شبکه‌های عصبی مصنوعی

درس ۸

رُویه‌های کارایی و نقاط بهینه

Performance Surfaces and Optimum Points

کاظم فولادی قلعه

دانشکده مهندسی، پردیس فارابی

دانشگاه تهران

<http://courses.fouladi.ir/nn>



Performance Surfaces and Optimum Points

رویه‌های کارآیی و نقاط بهینه

PERFORMANCE SURFACES AND OPTIMUM POINTS

یکی از تکنیک‌های پایه برای آموزش شبکه‌ی عصبی: تکنیک یادگیری کارآیی (پارامترهای شبکه تنظیم می‌شوند تا کارآیی شبکه بهینه شود)

سایر تکنیک‌ها: یادگیری انجمنی، یادگیری رقابتی

هدف این فصل: بررسی رویه‌های کارآیی و تعیین شرایط وجود ماکزیمم‌ها و می‌نیمم‌های آن

دو گام برای
فرآیند
بهینه‌سازی

- i. تعریف کارآیی: شاخص کارآیی: تابع هزینه
- ii. جستجو در فضای پارامتر: تنظیم وزن‌ها و بایاس‌ها به منظور بهبود شاخص کارآیی

شاخص کارآیی مورد نظر برای می‌نیمم‌سازی را با $F(x)$ نمایش می‌دهیم.
 x : اسکالری که باید تنظیم شود.

فرض: تابع F تحلیلی است (یعنی تمام مشتقات آن موجود است)

رُویه های کارایی و نقاط بهینه



سری
تیلور

Taylor Series Expansion



$$\begin{aligned} F(x) = & F(x^*) + \frac{d}{dx}F(x) \Big|_{x=x^*} (x-x^*) \\ & + \frac{1}{2} \frac{d^2}{dx^2} F(x) \Big|_{x=x^*} (x-x^*)^2 + \dots \\ & + \frac{1}{n!} \frac{d^n}{dx^n} F(x) \Big|_{x=x^*} (x-x^*)^n + \dots \end{aligned}$$

بسط سری تیلور

TAYLOR SERIES EXPANSION

$$\begin{aligned}
 F(x) = & F(x^*) + \left. \frac{d}{dx}F(x) \right|_{x=x^*} (x - x^*) \\
 & + \left. \frac{1}{2} \frac{d^2}{dx^2}F(x) \right|_{x=x^*} (x - x^*)^2 + \dots \\
 & + \left. \frac{1}{n!} \frac{d^n}{dx^n}F(x) \right|_{x=x^*} (x - x^*)^n + \dots
 \end{aligned}$$

استفاده از بسط سری تیلور برای تقریب زدن شاخص کارایی:
با محدود کردن تعداد جملات

Example



$$F(x) = e^{-x}$$

Taylor series of $F(x)$ about $x^* = 0$:

$$F(x) = e^{-x} = e^{-0} - e^{-0}(x-0) + \frac{1}{2}e^{-0}(x-0)^2 - \frac{1}{6}e^{-0}(x-0)^3 + \dots$$

$$F(x) = 1 - x + \frac{1}{2}x^2 - \frac{1}{6}x^3 + \dots$$

Taylor series approximations:

$$F(x) \approx F_0(x) = 1$$

$$F(x) \approx F_1(x) = 1 - x$$

$$F(x) \approx F_2(x) = 1 - x + \frac{1}{2}x^2$$

بسط سری تیلور

مثال

TAYLOR SERIES EXPANSION

$$F(x) = e^{-x}$$

Taylor series of $F(x)$ about $x^*=0$:

$$F(x) = e^{-x} = e^{-0} - e^{-0}(x-0) + \frac{1}{2}e^{-0}(x-0)^2 - \frac{1}{6}e^{-0}(x-0)^3 + \dots$$

$$F(x) = 1 - x + \frac{1}{2}x^2 - \frac{1}{6}x^3 + \dots$$

Taylor series approximations:

$$F(x) \approx F_0(x) = 1$$


تقریب مرتبه صفر
Zeroth-Order Approximation

$$F(x) \approx F_1(x) = 1 - x$$

تقریب مرتبه یک
First-Order Approximation

$$F(x) \approx F_2(x) = 1 - x + \frac{1}{2}x^2$$

تقریب مرتبه دو
Second-Order Approximation




بسط سری تیلور

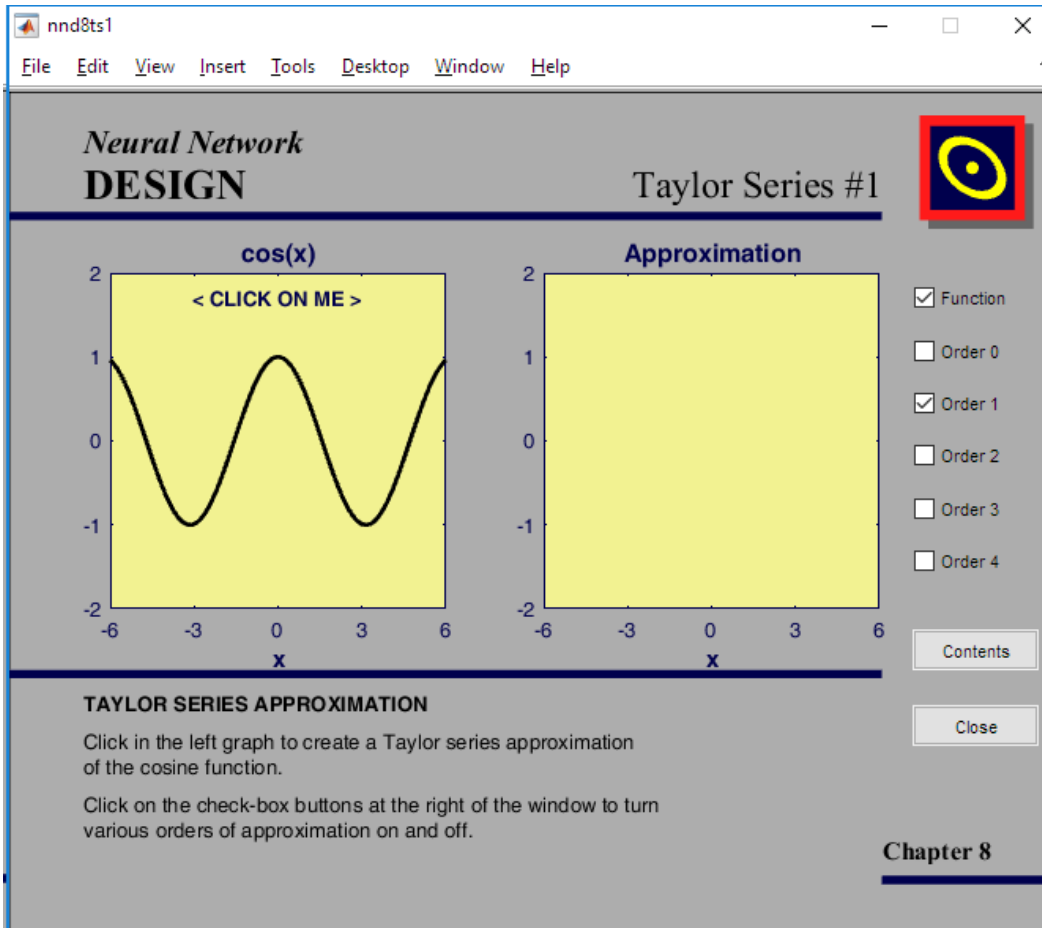
مثال: ترسیم تقریب‌ها

TAYLOR SERIES EXPANSION

همه‌ی تقریب‌ها دقیق هستند اگر x بسیار نزدیک به صفر باشد.
با دور شدن از صفر، تقریب‌های مرتبه بالاتر دقیق‌تر هستند.



از تقریب‌های سری تیلور شاخص کارایی (تابع هزینه) برای بررسی شکل تابع در همسایگی نقاط بهینه‌ی ممکن استفاده می‌کنیم.



>> nnd8ts1



$$F(\mathbf{x}) = F(x_1, x_2, \dots, x_n)$$

$$\begin{aligned} F(\mathbf{x}) = & F(\mathbf{x}^*) + \frac{\partial}{\partial x_1} F(\mathbf{x}) \Big|_{\mathbf{x} = \mathbf{x}^*} (x_1 - x_1^*) + \frac{\partial}{\partial x_2} F(\mathbf{x}) \Big|_{\mathbf{x} = \mathbf{x}^*} (x_2 - x_2^*) \\ & + \dots + \frac{\partial}{\partial x_n} F(\mathbf{x}) \Big|_{\mathbf{x} = \mathbf{x}^*} (x_n - x_n^*) + \frac{1}{2} \frac{\partial^2}{\partial x_1^2} F(\mathbf{x}) \Big|_{\mathbf{x} = \mathbf{x}^*} (x_1 - x_1^*)^2 \\ & + \frac{1}{2} \frac{\partial^2}{\partial x_1 \partial x_2} F(\mathbf{x}) \Big|_{\mathbf{x} = \mathbf{x}^*} (x_1 - x_1^*) (x_2 - x_2^*) + \dots \end{aligned}$$

بسط سری تیلور

حالت برداری (چند متغیره)

TAYLOR SERIES EXPANSION: VECTOR CASE

$$F(\mathbf{x}) = F(x_1, x_2, \dots, x_n)$$

$$\begin{aligned}
 F(\mathbf{x}) = & F(\mathbf{x}^*) + \frac{\partial}{\partial x_1} F(\mathbf{x}) \Big|_{\mathbf{x} = \mathbf{x}^*} (x_1 - x_1^*) + \frac{\partial}{\partial x_2} F(\mathbf{x}) \Big|_{\mathbf{x} = \mathbf{x}^*} (x_2 - x_2^*) \\
 & + \dots + \frac{\partial}{\partial x_n} F(\mathbf{x}) \Big|_{\mathbf{x} = \mathbf{x}^*} (x_n - x_n^*) + \frac{1}{2} \frac{\partial^2}{\partial x_1^2} F(\mathbf{x}) \Big|_{\mathbf{x} = \mathbf{x}^*} (x_1 - x_1^*)^2 \\
 & + \frac{1}{2} \frac{\partial^2}{\partial x_1 \partial x_2} F(\mathbf{x}) \Big|_{\mathbf{x} = \mathbf{x}^*} (x_1 - x_1^*)(x_2 - x_2^*) + \dots
 \end{aligned}$$

$F(\mathbf{x})$ تابعی از بردار \mathbf{x} شامل همه‌ی پارامترهای شبکه است.



$$F(\mathbf{x}) = F(\mathbf{x}^*) + \nabla F(\mathbf{x})^T \Big|_{\mathbf{x}=\mathbf{x}^*} (\mathbf{x} - \mathbf{x}^*) \\ + \frac{1}{2} (\mathbf{x} - \mathbf{x}^*)^T \nabla^2 F(\mathbf{x}) \Big|_{\mathbf{x}=\mathbf{x}^*} (\mathbf{x} - \mathbf{x}^*) + \dots$$

Gradient

$$\nabla F(\mathbf{x}) = \begin{bmatrix} \frac{\partial}{\partial x_1} F(\mathbf{x}) \\ \frac{\partial}{\partial x_2} F(\mathbf{x}) \\ \vdots \\ \frac{\partial}{\partial x_n} F(\mathbf{x}) \end{bmatrix}$$

Hessian

$$\nabla^2 F(\mathbf{x}) = \begin{bmatrix} \frac{\partial^2}{\partial x_1^2} F(\mathbf{x}) & \frac{\partial^2}{\partial x_1 \partial x_2} F(\mathbf{x}) & \dots & \frac{\partial^2}{\partial x_1 \partial x_n} F(\mathbf{x}) \\ \frac{\partial^2}{\partial x_2 \partial x_1} F(\mathbf{x}) & \frac{\partial^2}{\partial x_2^2} F(\mathbf{x}) & \dots & \frac{\partial^2}{\partial x_2 \partial x_n} F(\mathbf{x}) \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2}{\partial x_n \partial x_1} F(\mathbf{x}) & \frac{\partial^2}{\partial x_n \partial x_2} F(\mathbf{x}) & \dots & \frac{\partial^2}{\partial x_n^2} F(\mathbf{x}) \end{bmatrix}$$

بسط سری تیلور

حالت برداری (چند متغیره): فرم ماتریسی

TAYLOR SERIES EXPANSION: VECTOR CASE: MATRIX FORM

$$F(\mathbf{x}) = F(\mathbf{x}^*) + \nabla F(\mathbf{x})^T \Big|_{\mathbf{x} = \mathbf{x}^*} (\mathbf{x} - \mathbf{x}^*) + \frac{1}{2} (\mathbf{x} - \mathbf{x}^*)^T \nabla^2 F(\mathbf{x}) \Big|_{\mathbf{x} = \mathbf{x}^*} (\mathbf{x} - \mathbf{x}^*) + \dots$$

مشتقات اول
گرادین

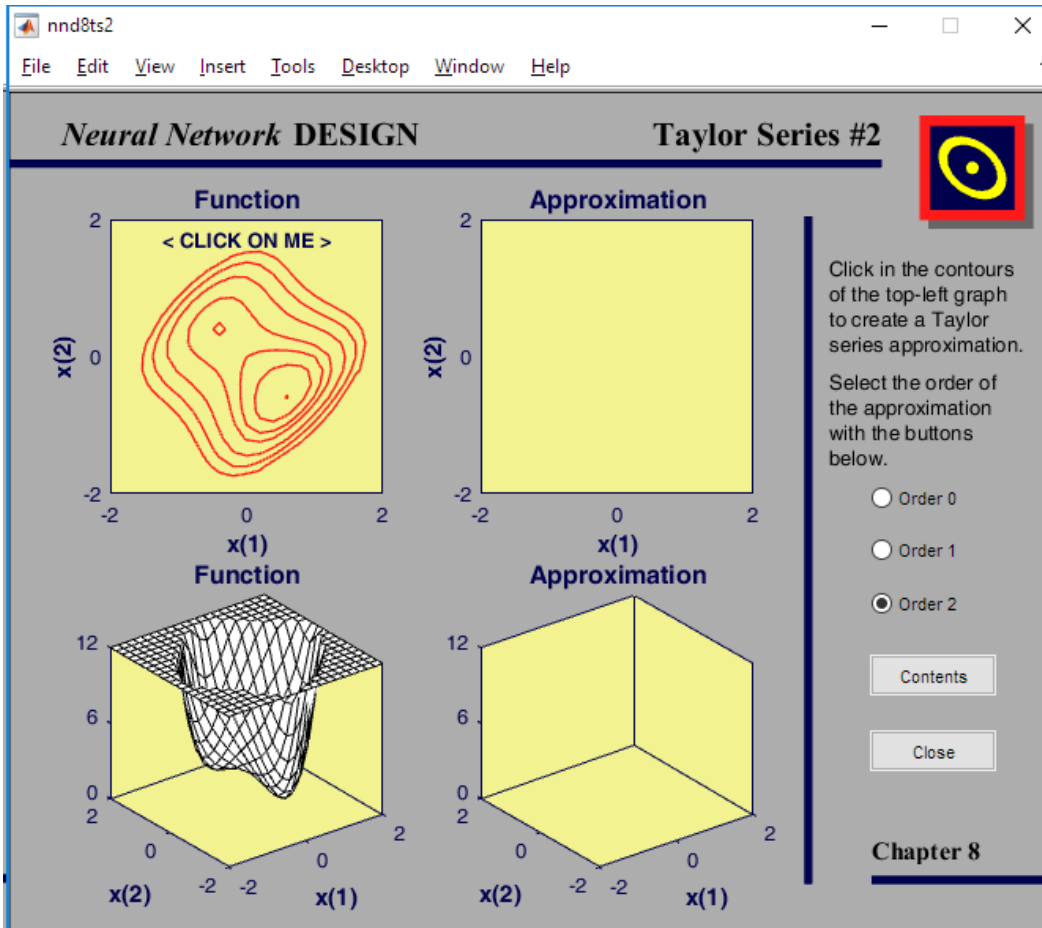
Gradient

$$\nabla F(\mathbf{x}) = \begin{bmatrix} \frac{\partial}{\partial x_1} F(\mathbf{x}) \\ \frac{\partial}{\partial x_2} F(\mathbf{x}) \\ \vdots \\ \frac{\partial}{\partial x_n} F(\mathbf{x}) \end{bmatrix}$$

Hessian

مشتقات دوم
هسی

$$\nabla^2 F(\mathbf{x}) = \begin{bmatrix} \frac{\partial^2}{\partial x_1^2} F(\mathbf{x}) & \frac{\partial^2}{\partial x_1 \partial x_2} F(\mathbf{x}) & \dots & \frac{\partial^2}{\partial x_1 \partial x_n} F(\mathbf{x}) \\ \frac{\partial^2}{\partial x_2 \partial x_1} F(\mathbf{x}) & \frac{\partial^2}{\partial x_2^2} F(\mathbf{x}) & \dots & \frac{\partial^2}{\partial x_2 \partial x_n} F(\mathbf{x}) \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2}{\partial x_n \partial x_1} F(\mathbf{x}) & \frac{\partial^2}{\partial x_n \partial x_2} F(\mathbf{x}) & \dots & \frac{\partial^2}{\partial x_n^2} F(\mathbf{x}) \end{bmatrix}$$



>> nnd8ts2

رُویه های کارایی و نقاط بهینه

۲

مشتقات
جهتی



First derivative (slope) of $F(\mathbf{x})$ along x_i axis: $\partial F(\mathbf{x})/\partial x_i$

(i th element of gradient)

Second derivative (curvature) of $F(\mathbf{x})$ along x_i axis: $\partial^2 F(\mathbf{x})/\partial x_i^2$

(i,i element of Hessian)

First derivative (slope) of $F(\mathbf{x})$ along vector \mathbf{p} : $\frac{\mathbf{p}^T \nabla F(\mathbf{x})}{\|\mathbf{p}\|}$

Second derivative (curvature) of $F(\mathbf{x})$ along vector \mathbf{p} : $\frac{\mathbf{p}^T \nabla^2 F(\mathbf{x}) \mathbf{p}}{\|\mathbf{p}\|^2}$

مشتقات جهتی

DIRECTIONAL DERIVATIVES

First derivative (slope) of $F(\mathbf{x})$ along x_i axis: $\partial F(\mathbf{x})/\partial x_i$

(i th element of gradient)

Second derivative (curvature) of $F(\mathbf{x})$ along x_i axis: $\partial^2 F(\mathbf{x})/\partial x_i^2$

(i,i element of Hessian)

First derivative (slope) of $F(\mathbf{x})$ along vector \mathbf{p} :

$$\frac{\mathbf{p}^T \nabla F(\mathbf{x})}{\|\mathbf{p}\|}$$

مشتق در یک راستای دلخواه

باید گرادیان در بردار جهت یکه‌ی \mathbf{p} ضرب داخلی شود.

Second derivative (curvature) of $F(\mathbf{x})$ along vector \mathbf{p} :

$$\frac{\mathbf{p}^T \nabla^2 F(\mathbf{x}) \mathbf{p}}{\|\mathbf{p}\|^2}$$

Example



$$F(\mathbf{x}) = x_1^2 + 2x_1x_2 + 2x_2^2$$

$$\mathbf{x}^* = \begin{bmatrix} 0.5 \\ 0 \end{bmatrix} \quad \mathbf{p} = \begin{bmatrix} 1 \\ -1 \end{bmatrix}$$

$$\nabla F(\mathbf{x}) \Big|_{\mathbf{x} = \mathbf{x}^*} = \begin{bmatrix} \frac{\partial}{\partial x_1} F(\mathbf{x}) \\ \frac{\partial}{\partial x_2} F(\mathbf{x}) \end{bmatrix} \Big|_{\mathbf{x} = \mathbf{x}^*} = \begin{bmatrix} 2x_1 + 2x_2 \\ 2x_1 + 4x_2 \end{bmatrix} \Big|_{\mathbf{x} = \mathbf{x}^*} = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$$

$$\frac{\mathbf{p}^T \nabla F(\mathbf{x})}{\|\mathbf{p}\|} = \frac{\begin{bmatrix} 1 & -1 \end{bmatrix} \begin{bmatrix} 1 \\ 1 \end{bmatrix}}{\left\| \begin{bmatrix} 1 \\ -1 \end{bmatrix} \right\|} = \frac{0}{\sqrt{2}} = 0$$

مشتقات جهتی

مثال

DIRECTIONAL DERIVATIVES

$$F(\mathbf{x}) = x_1^2 + 2x_1x_2 + 2x_2^2$$

جهت دلخواه: $\mathbf{p} = \begin{bmatrix} 1 \\ -1 \end{bmatrix}$ نقطه‌ی کار: $\mathbf{x}^* = \begin{bmatrix} 0.5 \\ 0 \end{bmatrix}$

$$\nabla F(\mathbf{x}) \Big|_{\mathbf{x} = \mathbf{x}^*} = \begin{bmatrix} \frac{\partial}{\partial x_1} F(\mathbf{x}) \\ \frac{\partial}{\partial x_2} F(\mathbf{x}) \end{bmatrix} \Big|_{\mathbf{x} = \mathbf{x}^*} = \begin{bmatrix} 2x_1 + 2x_2 \\ 2x_1 + 4x_2 \end{bmatrix} \Big|_{\mathbf{x} = \mathbf{x}^*} = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$$

نکته:



- هر جهت عمود بر گرادیان، شیب صفر دارد.
- بیشترین شیب در جهت گرادیان است. (طول آن مهم نیست)

$$\frac{\mathbf{p}^T \nabla F(\mathbf{x})}{\|\mathbf{p}\|} = \frac{\begin{bmatrix} 1 & -1 \end{bmatrix} \begin{bmatrix} 1 \\ 1 \end{bmatrix}}{\left\| \begin{bmatrix} 1 \\ -1 \end{bmatrix} \right\|} = \frac{\begin{bmatrix} 0 \end{bmatrix}}{\sqrt{2}} = 0$$

شیب تابع در راستای \mathbf{p} در نقطه‌ی \mathbf{x}^* صفر است.



Directional Derivatives





مشتقات جهتی

مثال: نمودار

DIRECTIONAL DERIVATIVES

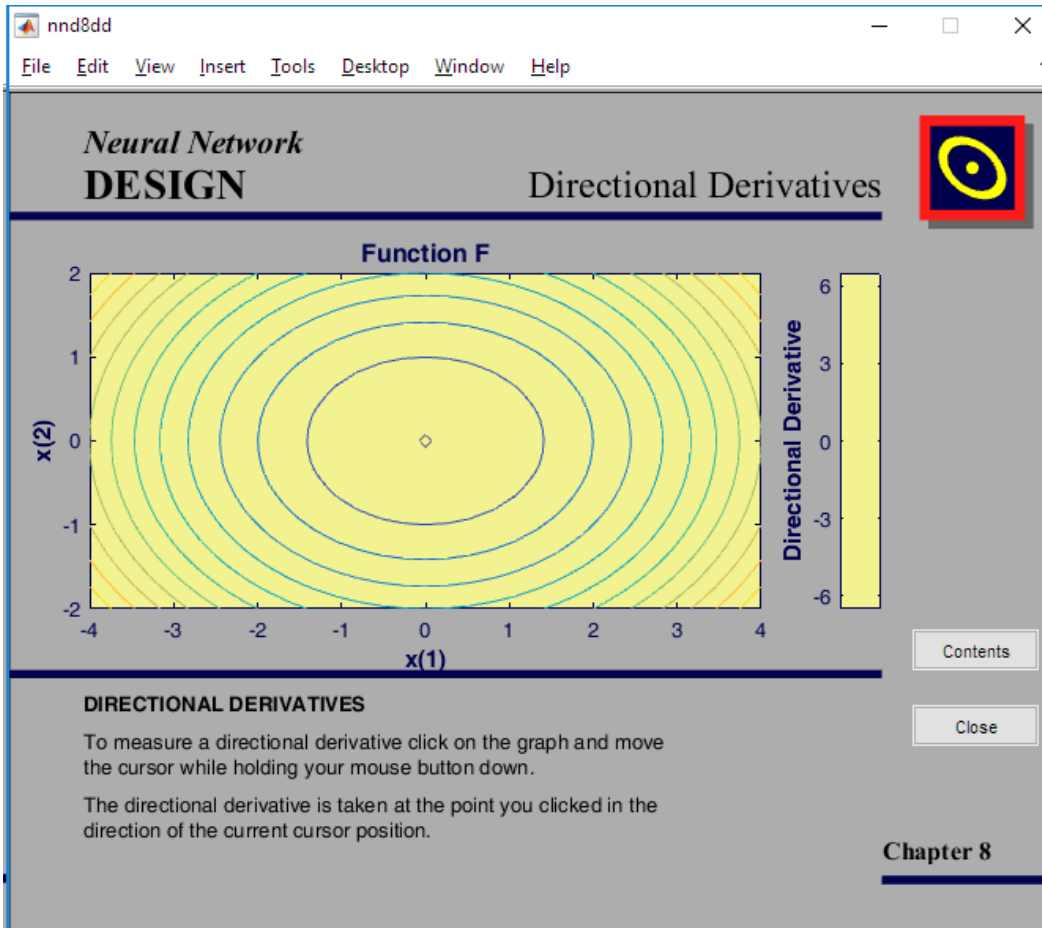
$$F(\mathbf{x}) = x_1^2 + 2x_1x_2 + 2x_2^2$$

Directional Derivatives



(مقدار تابع بر روی هر کانتور ثابت است.)

نمودار کانتوری
contour plot



>> nnd8dd

رُویه های کارایی و نقاط بهینه

۳

نقاط
می نیمم



Strong Minimum

The point \mathbf{x}^* is a strong minimum of $F(\mathbf{x})$ if a scalar $\delta > 0$ exists, such that $F(\mathbf{x}^*) < F(\mathbf{x}^* + \Delta\mathbf{x})$ for all $\Delta\mathbf{x}$ such that $\delta > \|\Delta\mathbf{x}\| > 0$.

Global Minimum

The point \mathbf{x}^* is a unique global minimum of $F(\mathbf{x})$ if $F(\mathbf{x}^*) < F(\mathbf{x}^* + \Delta\mathbf{x})$ for all $\Delta\mathbf{x} \neq 0$.

Weak Minimum

The point \mathbf{x}^* is a weak minimum of $F(\mathbf{x})$ if it is not a strong minimum, and a scalar $\delta > 0$ exists, such that $F(\mathbf{x}^*) \leq F(\mathbf{x}^* + \Delta\mathbf{x})$ for all $\Delta\mathbf{x}$ such that $\delta > \|\Delta\mathbf{x}\| > 0$.

می‌نیم‌ها

MINIMA

می‌نیم محلی

Strong Minimum

می‌نیم قوی

The point \mathbf{x}^* is a strong minimum of $F(\mathbf{x})$ if a scalar $\delta > 0$ exists, such that $F(\mathbf{x}^*) < F(\mathbf{x}^* + \Delta\mathbf{x})$ for all $\Delta\mathbf{x}$ such that $\delta > \|\Delta\mathbf{x}\| > 0$.

اگر از می‌نیم قوی (محلی) در هر جهتی به میزان فاصله‌ی کمی دور شویم، مقدار تابع افزایش می‌یابد.

می‌نیم مطلق

Global Minimum

می‌نیم سراسری

The point \mathbf{x}^* is a unique global minimum of $F(\mathbf{x})$ if $F(\mathbf{x}^*) < F(\mathbf{x}^* + \Delta\mathbf{x})$ for all $\Delta\mathbf{x} \neq 0$.

Weak Minimum

می‌نیم ضعیف


The point \mathbf{x}^* is a weak minimum of $F(\mathbf{x})$ if it is not a strong minimum, and a scalar $\delta > 0$ exists, such that $F(\mathbf{x}^*) \leq F(\mathbf{x}^* + \Delta\mathbf{x})$ for all $\Delta\mathbf{x}$ such that $\delta > \|\Delta\mathbf{x}\| > 0$.

می‌نیم ضعیف مانند می‌نیم قوی است اما مقدار تابع در بعضی جهت‌ها ممکن است ثابت بماند.

Scalar Example



$$F(x) = 3x^4 - 7x^2 - \frac{1}{2}x + 6$$




می‌نیم‌ها

مثال اسکالر

MINIMA



$$F(x) = 3x^4 - 7x^2 - \frac{1}{2}x + 6$$





Vector Example



$$F(\mathbf{x}) = (x_2 - x_1)^4 + 8x_1x_2 - x_1 + x_2 + 3$$



$$F(\mathbf{x}) = (x_1^2 - 1.5x_1x_2 + 2x_2^2)x_1^2$$




می‌نیم‌ها


مثال برداری

MINIMA



$$F(\mathbf{x}) = (x_2 - x_1)^4 + 8x_1x_2 - x_1 + x_2 + 3$$



$$F(\mathbf{x}) = (x_1^2 - 1.5x_1x_2 + 2x_2^2)x_1^2$$



$x_1 = 0$
می‌نیم ضعیف



نقطه‌ی زینی
saddle point

(در یک راستا ماکزیمم محلی و در راستای عمود بر آن می‌نیم محلی است.)

رُویه های کارایی و نقاط بهینه

۴

شرایط لازم
برای
نقطه ی
بهینه



$$F(\mathbf{x}) = F(\mathbf{x}^* + \Delta\mathbf{x}) = F(\mathbf{x}^*) + \nabla F(\mathbf{x})^T \Big|_{\mathbf{x}=\mathbf{x}^*} \Delta\mathbf{x} + \frac{1}{2} \Delta\mathbf{x}^T \nabla^2 F(\mathbf{x}) \Big|_{\mathbf{x}=\mathbf{x}^*} \Delta\mathbf{x} + \dots$$

$$\Delta\mathbf{x} = \mathbf{x} - \mathbf{x}^*$$

For small $\Delta\mathbf{x}$:

If \mathbf{x}^* is a minimum, this implies:

$$F(\mathbf{x}^* + \Delta\mathbf{x}) \cong F(\mathbf{x}^*) + \nabla F(\mathbf{x})^T \Big|_{\mathbf{x}=\mathbf{x}^*} \Delta\mathbf{x}$$

$$\nabla F(\mathbf{x})^T \Big|_{\mathbf{x}=\mathbf{x}^*} \Delta\mathbf{x} \geq 0$$

If $\nabla F(\mathbf{x})^T \Big|_{\mathbf{x}=\mathbf{x}^*} \Delta\mathbf{x} > 0$ then $F(\mathbf{x}^* - \Delta\mathbf{x}) \cong F(\mathbf{x}^*) - \nabla F(\mathbf{x})^T \Big|_{\mathbf{x}=\mathbf{x}^*} \Delta\mathbf{x} < F(\mathbf{x}^*)$

But this would imply that \mathbf{x}^* is not a minimum. Therefore $\nabla F(\mathbf{x})^T \Big|_{\mathbf{x}=\mathbf{x}^*} \Delta\mathbf{x} = 0$

Since this must be true for every $\Delta\mathbf{x}$,

$$\nabla F(\mathbf{x}) \Big|_{\mathbf{x}=\mathbf{x}^*} = \mathbf{0}$$

شرایط لازم برای بهینگی

شرایط مرتبه اول

FIRST-ORDER OPTIMALITY CONDITION

$$F(\mathbf{x}) = F(\mathbf{x}^* + \Delta\mathbf{x}) = F(\mathbf{x}^*) + \nabla F(\mathbf{x})^T \Big|_{\mathbf{x}=\mathbf{x}^*} \Delta\mathbf{x} + \frac{1}{2} \Delta\mathbf{x}^T \nabla^2 F(\mathbf{x}) \Big|_{\mathbf{x}=\mathbf{x}^*} \Delta\mathbf{x} + \dots$$

$$\Delta\mathbf{x} = \mathbf{x} - \mathbf{x}^*$$

برای می‌نیم لازم است که:

For small $\Delta\mathbf{x}$: جملات مرتبه بالاتر قابل چشم‌پوشی است

If \mathbf{x}^* is a minimum, this implies:

$$F(\mathbf{x}^* + \Delta\mathbf{x}) \cong F(\mathbf{x}^*) + \nabla F(\mathbf{x})^T \Big|_{\mathbf{x}=\mathbf{x}^*} \Delta\mathbf{x}$$

$$\nabla F(\mathbf{x})^T \Big|_{\mathbf{x}=\mathbf{x}^*} \Delta\mathbf{x} \geq 0$$

If $\nabla F(\mathbf{x})^T \Big|_{\mathbf{x}=\mathbf{x}^*} \Delta\mathbf{x} > 0$ then $F(\mathbf{x}^* - \Delta\mathbf{x}) \cong F(\mathbf{x}^*) - \nabla F(\mathbf{x})^T \Big|_{\mathbf{x}=\mathbf{x}^*} \Delta\mathbf{x} < F(\mathbf{x}^*)$ ✖

But this would imply that \mathbf{x}^* is not a minimum. Therefore $\nabla F(\mathbf{x})^T \Big|_{\mathbf{x}=\mathbf{x}^*} \Delta\mathbf{x} = 0$ پس:

Since this must be true for every $\Delta\mathbf{x}$,

$$\nabla F(\mathbf{x}) \Big|_{\mathbf{x}=\mathbf{x}^*} = \mathbf{0}$$

برای هر $\Delta\mathbf{x}$ داریم:

نقطه‌ی ایستادن stationary point

هر نقطه‌ای که این شرط (گرادیان صفر) را دارا باشد، نقطه‌ی ایستادن نام دارد (شرط لازم و نه کافی برای می‌نیم بودن).



If the first-order condition is satisfied (zero gradient), then

$$F(\mathbf{x}^* + \Delta\mathbf{x}) = F(\mathbf{x}^*) + \frac{1}{2}\Delta\mathbf{x}^T \nabla^2 F(\mathbf{x}) \Big|_{\mathbf{x} = \mathbf{x}^*} \Delta\mathbf{x} + \dots$$

A strong minimum will exist at \mathbf{x}^* if $\Delta\mathbf{x}^T \nabla^2 F(\mathbf{x}) \Big|_{\mathbf{x} = \mathbf{x}^*} \Delta\mathbf{x} > 0$ for any $\Delta\mathbf{x} \neq \mathbf{0}$.

Therefore the Hessian matrix must be positive definite. A matrix \mathbf{A} is positive definite if:

$$\mathbf{z}^T \mathbf{A} \mathbf{z} > 0 \quad \text{for any } \mathbf{z} \neq \mathbf{0}.$$

This is a **sufficient** condition for optimality.

A **necessary** condition is that the Hessian matrix be positive semidefinite. A matrix \mathbf{A} is positive semidefinite if:

$$\mathbf{z}^T \mathbf{A} \mathbf{z} \geq 0 \quad \text{for any } \mathbf{z}.$$

شرایط لازم برای بهینگی

شرایط مرتبه دوم

SECOND-ORDER CONDITION

برای نقطه‌ی ایستادن \mathbf{x}^* داریم: If the first-order condition is satisfied (zero gradient), then

$$F(\mathbf{x}^* + \Delta\mathbf{x}) = F(\mathbf{x}^*) + \frac{1}{2}\Delta\mathbf{x}^T \nabla^2 F(\mathbf{x}) \Big|_{\mathbf{x} = \mathbf{x}^*} \Delta\mathbf{x} + \dots$$

A strong minimum will exist at \mathbf{x}^* if $\Delta\mathbf{x}^T \nabla^2 F(\mathbf{x}) \Big|_{\mathbf{x} = \mathbf{x}^*} \Delta\mathbf{x} > 0$ for any $\Delta\mathbf{x} \neq \mathbf{0}$.

Therefore the Hessian matrix must be positive definite. A matrix \mathbf{A} is positive definite if:

شرط کافی برای بهینگی:
ماتریس هسی باید معین مثبت باشد

$$\mathbf{z}^T \mathbf{A} \mathbf{z} > 0$$

همه‌ی مقادیر ویژه مثبت باشد for any $\mathbf{z} \neq \mathbf{0}$.

This is a **sufficient** condition for optimality.

A **necessary** condition is that the Hessian matrix be positive semidefinite. A matrix \mathbf{A} is positive semidefinite if:

شرط لازم برای بهینگی:
ماتریس هسی باید نیمه معین مثبت باشد

$$\mathbf{z}^T \mathbf{A} \mathbf{z} \geq 0$$

همه‌ی مقادیر ویژه نامنفی باشد for any \mathbf{z} .

اگر جمله‌ی مرتبه دوم صفر باشد، اما جمله‌ی مرتبه سوم مثبت باشد، باز هم می‌توان می‌نیم محلی داشت.

Example



$$F(\mathbf{x}) = x_1^2 + 2x_1x_2 + 2x_2^2 + x_1$$

$$\nabla F(\mathbf{x}) = \begin{bmatrix} 2x_1 + 2x_2 + 1 \\ 2x_1 + 4x_2 \end{bmatrix} = \mathbf{0} \quad \Rightarrow \quad \mathbf{x}^* = \begin{bmatrix} -1 \\ 0.5 \end{bmatrix}$$

$$\nabla^2 F(\mathbf{x}) = \begin{bmatrix} 2 & 2 \\ 2 & 4 \end{bmatrix} \quad (\text{Not a function of } \mathbf{x} \text{ in this case.})$$

To test the definiteness, check the eigenvalues of the Hessian. If the eigenvalues are all greater than zero, the Hessian is positive definite.

$$|\nabla^2 F(\mathbf{x}) - \lambda \mathbf{I}| = \left| \begin{bmatrix} 2 - \lambda & 2 \\ 2 & 4 - \lambda \end{bmatrix} \right| = \lambda^2 - 6\lambda + 4 = (\lambda - 0.76)(\lambda - 5.24)$$

$\lambda = 0.76, 5.24$ Both eigenvalues are positive, therefore strong minimum.

شرایط لازم برای بهینگی

مثال

$$F(\mathbf{x}) = x_1^2 + 2x_1x_2 + 2x_2^2 + x_1$$

$$\nabla F(\mathbf{x}) = \begin{bmatrix} 2x_1 + 2x_2 + 1 \\ 2x_1 + 4x_2 \end{bmatrix} = \mathbf{0} \quad \Rightarrow \quad \mathbf{x}^* = \begin{bmatrix} -1 \\ 0.5 \end{bmatrix}$$

$$\nabla^2 F(\mathbf{x}) = \begin{bmatrix} 2 & 2 \\ 2 & 4 \end{bmatrix} \quad (\text{Not a function of } \mathbf{x} \text{ in this case.})$$

To test the definiteness, check the eigenvalues of the Hessian. If the eigenvalues are all greater than zero, the Hessian is positive definite.

$$|\nabla^2 F(\mathbf{x}) - \lambda \mathbf{I}| = \left| \begin{bmatrix} 2 - \lambda & 2 \\ 2 & 4 - \lambda \end{bmatrix} \right| = \lambda^2 - 6\lambda + 4 = (\lambda - 0.76)(\lambda - 5.24)$$

$$\lambda = 0.76, 5.24$$

Both eigenvalues are positive, therefore strong minimum.

رُویه های کارایی و نقاط بهینه

۵

توابع
مربعی

Quadratic Functions



$$F(\mathbf{x}) = \frac{1}{2}\mathbf{x}^T \mathbf{A}\mathbf{x} + \mathbf{d}^T \mathbf{x} + c \quad (\text{Symmetric } \mathbf{A})$$

Gradient and Hessian:

Useful properties of gradients:

$$\nabla(\mathbf{h}^T \mathbf{x}) = \nabla(\mathbf{x}^T \mathbf{h}) = \mathbf{h}$$

$$\nabla \mathbf{x}^T \mathbf{Q} \mathbf{x} = \mathbf{Q} \mathbf{x} + \mathbf{Q}^T \mathbf{x} = 2\mathbf{Q} \mathbf{x} \quad (\text{for symmetric } \mathbf{Q})$$

Gradient of Quadratic Function:

$$\nabla F(\mathbf{x}) = \mathbf{A}\mathbf{x} + \mathbf{d}$$

Hessian of Quadratic Function:

$$\nabla^2 F(\mathbf{x}) = \mathbf{A}$$

تابع درجه دوم

تابع مربعی

QUADRATIC FUNCTIONS

$$F(\mathbf{x}) = \frac{1}{2} \mathbf{x}^T \mathbf{A} \mathbf{x} + \mathbf{d}^T \mathbf{x} + c \quad (\text{Symmetric } \mathbf{A})$$

Gradient and Hessian:

Useful properties of gradients:

$$\nabla(\mathbf{h}^T \mathbf{x}) = \nabla(\mathbf{x}^T \mathbf{h}) = \mathbf{h}$$

$$\nabla \mathbf{x}^T \mathbf{Q} \mathbf{x} = \mathbf{Q} \mathbf{x} + \mathbf{Q}^T \mathbf{x} = 2 \mathbf{Q} \mathbf{x} \quad (\text{for symmetric } \mathbf{Q})$$

Gradient of Quadratic Function:

$$\nabla F(\mathbf{x}) = \mathbf{A} \mathbf{x} + \mathbf{d}$$

Hessian of Quadratic Function:

$$\nabla^2 F(\mathbf{x}) = \mathbf{A}$$

همه‌ی مشتقات مرتبه بالاتر آن صفر است.

Eigensystem of the Hessian



Consider a quadratic function which has a stationary point at the origin, and whose value there is zero.

$$F(\mathbf{x}) = \frac{1}{2} \mathbf{x}^T \mathbf{A} \mathbf{x}$$

Perform a similarity transform on the Hessian matrix, using the eigenvalues as the new basis vectors.

$$\mathbf{B} = \begin{bmatrix} \mathbf{z}_1 & \mathbf{z}_2 & \dots & \mathbf{z}_n \end{bmatrix}$$

Since the Hessian matrix is symmetric, its eigenvectors are orthogonal.

$$\mathbf{B}^{-1} = \mathbf{B}^T$$

$$\mathbf{A}' = [\mathbf{B}^T \mathbf{A} \mathbf{B}] = \begin{bmatrix} \lambda_1 & 0 & \dots & 0 \\ 0 & \lambda_2 & \dots & 0 \\ \vdots & \vdots & & \vdots \\ 0 & 0 & \dots & \lambda_n \end{bmatrix} = \Lambda \quad \mathbf{A} = \mathbf{B} \Lambda \mathbf{B}^T$$

سیستم ویژه‌ی هسی

EIGENSYSTEM OF THE HESSIAN

Consider a quadratic function which has a stationary point at the origin, and whose value there is zero.

$$F(\mathbf{x}) = \frac{1}{2} \mathbf{x}^T \mathbf{A} \mathbf{x}$$

Perform a similarity transform on the Hessian matrix, using the eigenvalues as the new basis vectors.

$$\mathbf{B} = \begin{bmatrix} \mathbf{z}_1 & \mathbf{z}_2 & \dots & \mathbf{z}_n \end{bmatrix} \quad \begin{array}{l} \text{استفاده از} \\ \text{بردارهای ویژه‌ی ماتریس هسی به عنوان پایه} \end{array}$$

Since the Hessian matrix is symmetric, its eigenvectors are orthogonal.

$$\mathbf{B}^{-1} = \mathbf{B}^T$$

ماتری هسی متقارن است، پس بردارهای ویژه‌ی آن متعامد هستند.

$$\mathbf{A}' = [\mathbf{B}^T \mathbf{A} \mathbf{B}] = \begin{bmatrix} \lambda_1 & 0 & \dots & 0 \\ 0 & \lambda_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \lambda_n \end{bmatrix} = \Lambda \quad \mathbf{A} = \mathbf{B} \Lambda \mathbf{B}^T$$



$$\frac{\mathbf{p}^T \nabla^2 F(\mathbf{x}) \mathbf{p}}{\|\mathbf{p}\|^2} = \frac{\mathbf{p}^T \mathbf{A} \mathbf{p}}{\|\mathbf{p}\|^2}$$

Represent \mathbf{p} with respect to the eigenvectors (new basis):

$$\mathbf{p} = \mathbf{B} \mathbf{c}$$

$$\frac{\mathbf{p}^T \mathbf{A} \mathbf{p}}{\|\mathbf{p}\|^2} = \frac{\mathbf{c}^T \mathbf{B}^T (\mathbf{B} \mathbf{A} \mathbf{B}^T) \mathbf{B} \mathbf{c}}{\mathbf{c}^T \mathbf{B}^T \mathbf{B} \mathbf{c}} = \frac{\mathbf{c}^T \mathbf{\Lambda} \mathbf{c}}{\mathbf{c}^T \mathbf{c}} = \frac{\sum_{i=1}^n \lambda_i c_i^2}{\sum_{i=1}^n c_i^2}$$

$$\lambda_{\min} \leq \frac{\mathbf{p}^T \mathbf{A} \mathbf{p}}{\|\mathbf{p}\|^2} \leq \lambda_{\max}$$

سیستم ویژه‌ی هسی

مشتقات دوم جهت‌ی

SECOND DIRECTIONAL DERIVATIVE

$$\frac{\mathbf{p}^T \nabla^2 F(\mathbf{x}) \mathbf{p}}{\|\mathbf{p}\|^2} = \frac{\mathbf{p}^T \mathbf{A} \mathbf{p}}{\|\mathbf{p}\|^2}$$

مشتق دوم در راستای \mathbf{p} :Represent \mathbf{p} with respect to the eigenvectors (new basis):

$$\mathbf{p} = \mathbf{B} \mathbf{c}$$

تبدیل پایه‌ی \mathbf{p} به \mathbf{B} :

$$\frac{\mathbf{p}^T \mathbf{A} \mathbf{p}}{\|\mathbf{p}\|^2} = \frac{\mathbf{c}^T \mathbf{B}^T (\mathbf{B} \mathbf{A} \mathbf{B}^T) \mathbf{B} \mathbf{c}}{\mathbf{c}^T \mathbf{B}^T \mathbf{B} \mathbf{c}} = \frac{\mathbf{c}^T \mathbf{\Lambda} \mathbf{c}}{\mathbf{c}^T \mathbf{c}} = \frac{\sum_{i=1}^n \lambda_i c_i^2}{\sum_{i=1}^n c_i^2}$$

میانگین وزن‌دار
مقادیر ویژه
↓
بین بزرگ‌ترین و
کوچک‌ترین مقدار ویژه


$$\lambda_{min} \leq \frac{\mathbf{p}^T \mathbf{A} \mathbf{p}}{\|\mathbf{p}\|^2} \leq \lambda_{max}$$



$$\mathbf{p} = \mathbf{z}_{max} \quad \mathbf{c} = \mathbf{B}^T \mathbf{p} = \mathbf{B}^T \mathbf{z}_{max} = \begin{bmatrix} 0 \\ 0 \\ \vdots \\ 0 \\ 1 \\ 0 \\ \vdots \\ 0 \end{bmatrix}$$

$$\frac{\mathbf{z}_{max}^T \mathbf{A} \mathbf{z}_{max}}{\|\mathbf{z}_{max}\|^2} = \frac{\sum_{i=1}^n \lambda_i c_i^2}{\sum_{i=1}^n c_i^2} = \lambda_{max}$$

The eigenvalues represent curvature
(second derivatives) along the eigenvectors
(the principal axes).



سیستم ویژه‌ی هسی

بردار ویژه (متناظر با بزرگ‌ترین مقدار ویژه)

EIGENVECTOR (LARGEST EIGENVALUE)

مشتق دوم = بزرگ‌ترین مقدار ویژه


$$\mathbf{p} = \mathbf{z}_{max} \quad \mathbf{c} = \mathbf{B}^T \mathbf{p} = \mathbf{B}^T \mathbf{z}_{max} =$$

$$\begin{bmatrix} 0 \\ 0 \\ \vdots \\ 0 \\ 1 \\ 0 \\ \vdots \\ 0 \end{bmatrix}$$

فقط در یک نقطه،
1 می‌شود.
(زیرا بردارهای یکه،
متعامد یکه هستند)

$$\frac{\mathbf{z}_{max}^T \mathbf{A} \mathbf{z}_{max}}{\|\mathbf{z}_{max}\|^2} = \frac{\sum_{i=1}^n \lambda_i c_i^2}{\sum_{i=1}^n c_i^2} = \lambda_{max}$$

The eigenvalues represent curvature (second derivatives) along the eigenvectors (the principal axes).



* حالت:
هم علامت بودن هر دو مقدار ویژه

مقادیر ویژه، انحنای بردارهای ویژه را بازنمایی می‌کنند.



Circular Hollow



$$F(\mathbf{x}) = x_1^2 + x_2^2 = \frac{1}{2} \mathbf{x}^T \begin{bmatrix} 2 & 0 \\ 0 & 2 \end{bmatrix} \mathbf{x}$$

$$\nabla^2 F(\mathbf{x}) = \begin{bmatrix} 2 & 0 \\ 0 & 2 \end{bmatrix} \quad \lambda_1 = 2 \quad \mathbf{z}_1 = \begin{bmatrix} 1 \\ 0 \end{bmatrix} \quad \lambda_2 = 2 \quad \mathbf{z}_2 = \begin{bmatrix} 0 \\ 1 \end{bmatrix}$$

(Any two independent vectors in the plane would work.)



سیستم ویژه‌ی هسی



تابهیدگی دایره‌ای

CIRCULAR HOLLOW

$$F(\mathbf{x}) = x_1^2 + x_2^2 = \frac{1}{2} \mathbf{x}^T \begin{bmatrix} 2 & 0 \\ 0 & 2 \end{bmatrix} \mathbf{x}$$

$$\nabla^2 F(\mathbf{x}) = \begin{bmatrix} 2 & 0 \\ 0 & 2 \end{bmatrix} \quad \lambda_1 = 2 \quad \mathbf{z}_1 = \begin{bmatrix} 1 \\ 0 \end{bmatrix} \quad \lambda_2 = 2 \quad \mathbf{z}_2 = \begin{bmatrix} 0 \\ 1 \end{bmatrix}$$

(Any two independent vectors in the plane would work.)



* حالت:



تساوی مقادیر ویژه \Leftarrow انحنا در هر دو راستا مساوی است \Leftarrow کانتورهای دایره‌ای

Elliptical Hollow



$$F(\mathbf{x}) = x_1^2 + x_1x_2 + x_2^2 = \frac{1}{2}\mathbf{x}^T \begin{bmatrix} 2 & 1 \\ 1 & 2 \end{bmatrix} \mathbf{x}$$

$$\nabla^2 F(\mathbf{x}) = \begin{bmatrix} 2 & 1 \\ 1 & 2 \end{bmatrix} \quad \lambda_1 = 1 \quad \mathbf{z}_1 = \begin{bmatrix} 1 \\ -1 \end{bmatrix} \quad \lambda_2 = 3 \quad \mathbf{z}_2 = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$$





سیستم ویژه‌ی هسی

تابهیدگی بیضوی

ELLIPTICAL HOLLOW

$$F(\mathbf{x}) = x_1^2 + x_1x_2 + x_2^2 = \frac{1}{2}\mathbf{x}^T \begin{bmatrix} 2 & 1 \\ 1 & 2 \end{bmatrix} \mathbf{x}$$

$$\nabla^2 F(\mathbf{x}) = \begin{bmatrix} 2 & 1 \\ 1 & 2 \end{bmatrix} \quad \lambda_1 = 1 \quad \mathbf{z}_1 = \begin{bmatrix} 1 \\ -1 \end{bmatrix} \quad \lambda_2 = 3 \quad \mathbf{z}_2 = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$$



* حالت:



حداکثر انحنا در جهت بزرگ‌ترین مقدار ویژه است \Leftarrow کانتورها در این جهت به هم نزدیک هستند.

Elongated Saddle



$$F(\mathbf{x}) = -\frac{1}{4}x_1^2 - \frac{3}{2}x_1x_2 - \frac{1}{4}x_2^2 = \frac{1}{2}\mathbf{x}^T \begin{bmatrix} -0.5 & -1.5 \\ -1.5 & -0.5 \end{bmatrix} \mathbf{x}$$

$$\nabla^2 F(\mathbf{x}) = \begin{bmatrix} -0.5 & -1.5 \\ -1.5 & -0.5 \end{bmatrix} \quad \lambda_1 = 1 \quad \mathbf{z}_1 = \begin{bmatrix} -1 \\ 1 \end{bmatrix} \quad \lambda_2 = -2 \quad \mathbf{z}_2 = \begin{bmatrix} -1 \\ -1 \end{bmatrix}$$



سیستم ویژه‌ی هسی

زین ممتد کشیده

ELONGATED SADDLE

$$F(\mathbf{x}) = -\frac{1}{4}x_1^2 - \frac{3}{2}x_1x_2 - \frac{1}{4}x_2^2 = \frac{1}{2}\mathbf{x}^T \begin{bmatrix} -0.5 & -1.5 \\ -1.5 & -0.5 \end{bmatrix} \mathbf{x}$$


* حالت:

مقادیر ویژه‌ی ناهم‌علامت

$$\nabla^2 F(\mathbf{x}) = \begin{bmatrix} -0.5 & -1.5 \\ -1.5 & -0.5 \end{bmatrix} \quad \lambda_1 = 1 \quad \mathbf{z}_1 = \begin{bmatrix} -1 \\ 1 \end{bmatrix} \quad \lambda_2 = -2 \quad \mathbf{z}_2 = \begin{bmatrix} -1 \\ -1 \end{bmatrix}$$


انحنای مثبت در جهت \mathbf{z}_1
(اندازه‌ی کوچک‌تر، انحنای کمتر)

انحنای منفی در جهت \mathbf{z}_2
(اندازه‌ی بزرگ‌تر، انحنای بیشتر)



چون هسی
معین مثبت نیست،
پس
 $\mathbf{x}^* = 0$
نقطه‌ی زینی است.

در جهت \mathbf{z}_1 (می‌نیم، λ مثبت)
در جهت \mathbf{z}_2 (ماکزیم، λ منفی)





Stationary Valley



$$F(\mathbf{x}) = \frac{1}{2}x_1^2 - x_1x_2 + \frac{1}{2}x_2^2 = \frac{1}{2}\mathbf{x}^T \begin{bmatrix} 1 & -1 \\ -1 & 1 \end{bmatrix} \mathbf{x}$$

$$\nabla^2 F(\mathbf{x}) = \begin{bmatrix} 1 & -1 \\ -1 & 1 \end{bmatrix} \quad \lambda_1 = 1 \quad \mathbf{z}_1 = \begin{bmatrix} -1 \\ 1 \end{bmatrix} \quad \lambda_2 = 0 \quad \mathbf{z}_2 = \begin{bmatrix} -1 \\ -1 \end{bmatrix}$$



سیستم ویژه‌ی هسی

دره‌ی ایستان

STATIONARY VALLEY

$$F(\mathbf{x}) = \frac{1}{2}x_1^2 - x_1x_2 + \frac{1}{2}x_2^2 = \frac{1}{2}\mathbf{x}^T \begin{bmatrix} 1 & -1 \\ -1 & 1 \end{bmatrix} \mathbf{x}$$



* حالت:

یک مقدار ویژه صفر است.

$$\nabla^2 F(\mathbf{x}) = \begin{bmatrix} 1 & -1 \\ -1 & 1 \end{bmatrix} \quad \lambda_1 = 1 \quad \mathbf{z}_1 = \begin{bmatrix} -1 \\ 1 \end{bmatrix} \quad \lambda_2 = 0 \quad \mathbf{z}_2 = \begin{bmatrix} -1 \\ -1 \end{bmatrix}$$

در راستای \mathbf{z}_2 انحنا صفر استمی‌نیمم ضعیف در راستای \mathbf{z}_2

$$x_1 = x_2$$



نکته: توابع مرتبه بالاتر از دو می‌توانند با هسی نیمه معین مثبت، می‌نیمم قوی داشته باشند.

nnd8qf

File Edit View Insert Tools Desktop Window Help

Neural Network DESIGN Quadratic Function

Function F

Function F

Change the values of the Hessian matrix A, the vector d, and the constant c. Then click [Update] to see the new function.

Note that the Hessian matrix A will always be symmetric.

Chapter 8

$$F(x) = \frac{1}{2}x'Ax + d'x + c$$

$A = \begin{bmatrix} 1.5 & -0.7 \\ -0.7 & 1 \end{bmatrix}$

$d = \begin{bmatrix} 0.25 \\ 0.25 \end{bmatrix}$

$c = \begin{bmatrix} 1 \end{bmatrix}$



>> nnd8qf



- If the eigenvalues of the Hessian matrix are all positive, the function will have a single strong minimum.
- If the eigenvalues are all negative, the function will have a single strong maximum.
- If some eigenvalues are positive and other eigenvalues are negative, the function will have a single saddle point.
- If the eigenvalues are all nonnegative, but some eigenvalues are zero, then the function will either have a weak minimum or will have no stationary point.
- If the eigenvalues are all nonpositive, but some eigenvalues are zero, then the function will either have a weak maximum or will have no stationary point.

Stationary Point: $\mathbf{x}^* = -\mathbf{A}^{-1} \mathbf{d}$

خلاصه ویژگی‌های تابع درجه دوم

QUADRATIC FUNCTION SUMMARY

مقادیر ویژه‌ی هسی:

- همه مثبت \Leftarrow
یک min قوی
- همه منفی \Leftarrow
یک max قوی
- بعضی مثبت، بعضی منفی \Leftarrow
وجود نقطه‌ی زینی
- همه نامنفی، بعضی صفر \Leftarrow
وجود نقطه‌ی min ضعیف یا
عدم وجود نقطه‌ی زینی
- همه نامثبت، بعضی صفر \Leftarrow
وجود نقطه‌ی max ضعیف یا
عدم وجود نقطه‌ی زینی
- If the eigenvalues of the Hessian matrix are all positive, the function will have a single strong minimum.
- If the eigenvalues are all negative, the function will have a single strong maximum.
- If some eigenvalues are positive and other eigenvalues are negative, the function will have a single saddle point.
- If the eigenvalues are all nonnegative, but some eigenvalues are zero, then the function will either have a weak minimum or will have no stationary point.
- If the eigenvalues are all nonpositive, but some eigenvalues are zero, then the function will either have a weak maximum or will have no stationary point.

نقطه‌ی ایستادن


$$\text{Stationary Point: } \mathbf{x}^* = -\mathbf{A}^{-1} \mathbf{d}$$

رُویه های کارایی و نقاط بهینه

۶

منابع

منبع اصلی



Martin T. Hagan, Howard B. Demuth, Mark H. Beale, Orlando De Jesus,
Neural Network Design,
 2nd Edition, Martin Hagan, 2014.

Chapter 8

Online version can be downloaded from: <http://hagan.okstate.edu/nnd.html>

8 Performance Surfaces and Optimum Points

Objectives	8-1
Theory and Examples	8-2
Taylor Series	8-2
Vector Case	8-4
Directional Derivatives	8-5
Minima	8-7
Necessary Conditions for Optimality	8-9
First-Order Conditions	8-10
Second-Order Conditions	8-11
Quadratic Functions	8-12
Eigensystem of the Hessian	8-13
Summary of Results	8-20
Solved Problems	8-22
Epilogue	8-34
Further Reading	8-35
Exercises	8-36

Objectives

This chapter lays the foundation for a type of neural network training technique called performance learning. There are several different classes of network learning laws, including associative learning (as in the Hebbian learning of Chapter 7) and competitive learning (which we will discuss in Chapter 10). Performance learning is another important class of learning law, in which the network parameters are adjusted to optimize the performance of the network. In the next two chapters we will lay the groundwork for the development of performance learning, which will then be presented in detail in Chapters 10–14. The main objective of the present chapter is to investigate performance surfaces and to determine conditions for the existence of minima and maxima of the performance surface. Chapter 9 will follow this up with a discussion of procedures to locate the minima or maxima.

8-1