

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ



شبکه‌های عصبی مصنوعی

درس ۲۱

شبکه‌ی هاپفیلد

Hopfield Network

کاظم فولادی قلعه
دانشکده مهندسی، پردیس فارابی
دانشگاه تهران

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




Hopfield Network

شبکه‌ی هاپفیلد

HOPFIELD NETWORK

شبکه‌ی هاپفیلد نقش عمده‌ای در احیای پژوهش‌های شبکه‌های عصبی در اواخر دهه‌ی ۱۹۸۰ داشت.

استفاده از شبکه‌ی هاپفیلد برای پیاده‌سازی رفتار یک حافظه‌ی انجمنی



شبکه‌ی هاپفیلد

جان هاپفیلد

HOPFIELD NETWORK

هاپفیلد یک فیزیکدان بود:

- آغاز فعالیت‌ها با مطالعه درباره‌ی تعاملات بین نور و جامدات
 - بعدها، پژوهش بر روی مکانیسم انتقال الکترون‌ها بین مولکول‌های زنده
 - در نهایت، ترکیب فعالیت‌ها و مطالعات فیزیکی و ریاضیاتی با تجربیات بعدی او در زیست‌شناسی
- ← در قالب یک شبکه‌ی عصبی جدید (شبکه‌ی هاپفیلد)



John Hopfield (1933-)

مقالات تأثیرگذار هاپفیلد: ۱۹۸۲ و ۱۹۸۴:

- گردآوری مجموعه‌ای از ایده‌های مهم و بیان در قالب تحلیل‌های ریاضی روشن
- قیاس بین شبکه‌ی عصبی هاپفیلد و مدل آیزینگ در مغناطیس (← فیزیک آماری)
 - مطرح شدن ایده‌های جدید در رابطه با نسبت علم فیزیک و علم شبکه‌های عصبی
 - موجب تشویق بسیاری از فیزیکدان‌ها برای کار بر روی شبکه‌های عصبی در کنار مهندسان و پژوهشگران

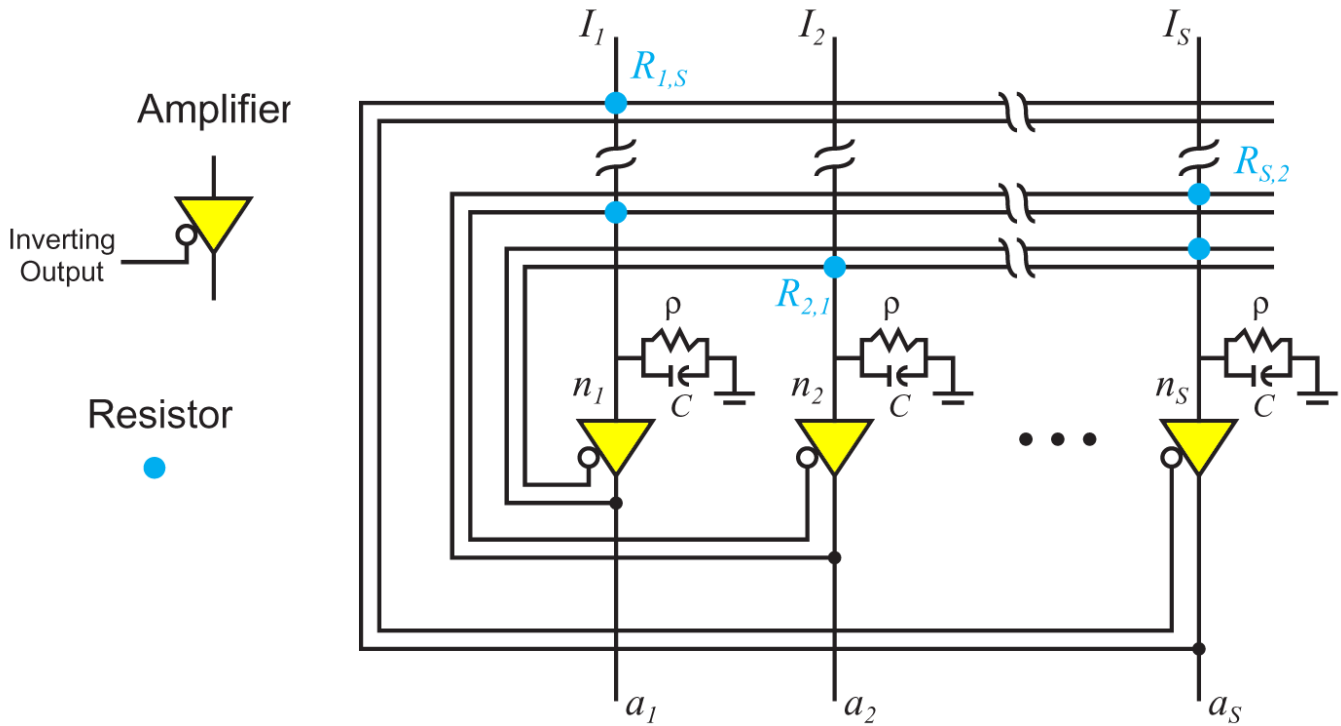
- همکاری طولانی مدت با آزمایشگاه AT&T بل و رابطه‌ی نزدیک با طراحان VLSI
- در اواسط ۱۹۸۷ آزمایشگاه بل موفق به توسعه‌ی یک تراشه‌ی شبکه‌ی عصبی بر مبنای شبکه‌ی هاپفیلد شد.
- این یکی از دلایل تمایز و برتری پژوهش‌های هاپفیلد نسبت به دیگران است.

شبکه‌ی هاپفیلد



مدل
هاپفیلد

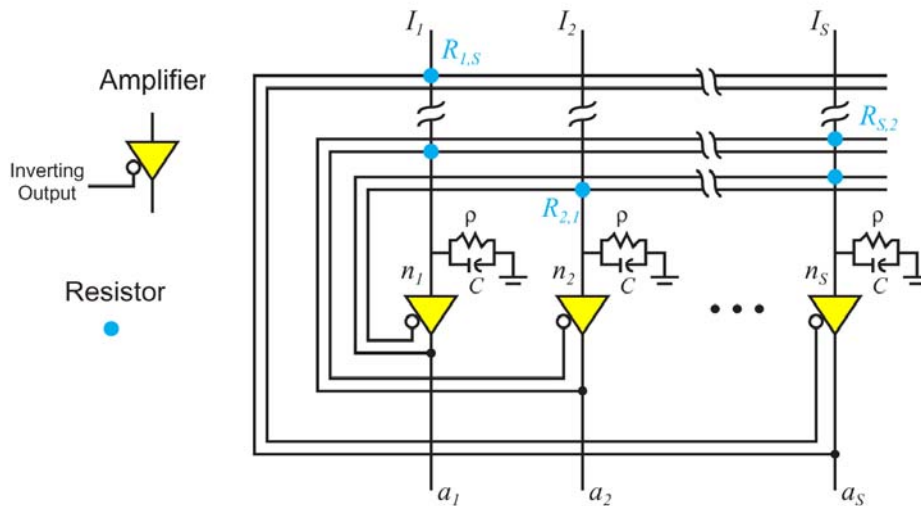
Hopfield Model



مدل هاپفیلد

HOPFIELD MODEL

هاپفیلد مدل خود را در قالب یک مدار الکتریکی ارائه کرد:



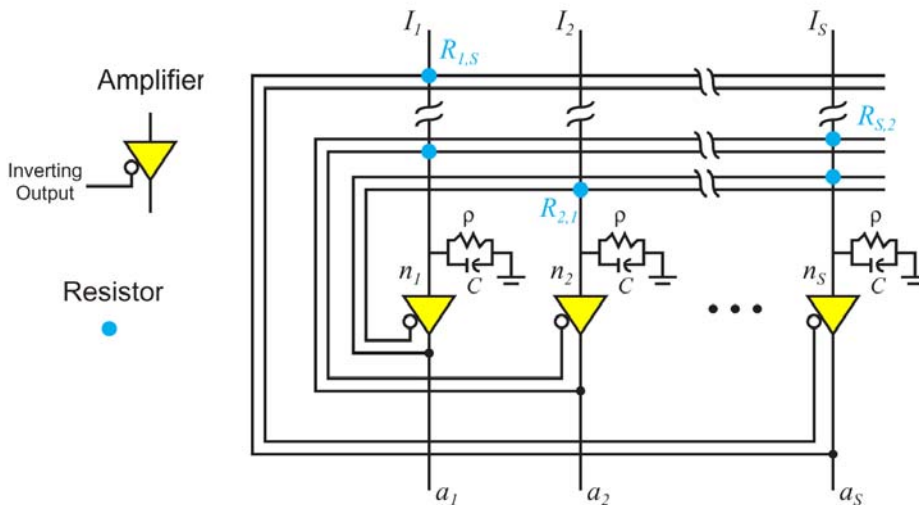
هر نرون، با یک تقویت‌کننده عملیاتی (Op-Amp) و شبکه‌ی مقاومت-خازن متصل به آن بازنمایی شده است.

نرون‌ها دارای دو مجموعه ورودی هستند:

- مجموعه‌ی اول: شامل جریان‌های I_1, I_2, \dots که ورودی‌های ثابت خارجی محسوب می‌شوند.
- مجموعه‌ی دوم: حاوی اتصالات فیدبک از سایر تقویت‌کننده‌های عملیاتی است.

مدل هاپفیلد

HOPFIELD MODEL



به عنوان نمونه: خروجی دوم a_2 به مقاومت $R_{S,2}$ وصل می‌شود (که به ورودی تقویت‌کننده‌ی S متصل است).

ورودی منفی به یک نرون از طریق انتخاب خروجی معکوس کننده از یک تقویت‌کننده قابل تدارک است.
(در شکل، خروجی معکوس‌کننده‌ی تقویت‌کننده‌ی اول از طریق مقاومت $R_{2,1}$ به ورودی تقویت‌کننده‌ی دوم متصل است.)



$$C \frac{dn_i(t)}{dt} = \sum_{j=1}^S T_{i,j} a_j(t) - \frac{n_i(t)}{R_i} + I_i$$

n_i - input voltage to the i th amplifier

a_i - output voltage of the i th amplifier

C - amplifier input capacitance

I_i - fixed input current to the i th amplifier

$$|T_{i,j}| = \frac{1}{R_{i,j}} \quad \frac{1}{R_i} = \frac{1}{\rho} + \sum_{j=1}^S \frac{1}{R_{i,j}} \quad n_i = f^{-1}(a_i) \quad a_i = f(n_i)$$


مدل هاپفیلد

معادلات عملکرد

EQUATIONS OF OPERATION

معادلات عملکرد مدل هاپفیلد بر اساس قانون جریان کیرشهف استخراج می‌شود:

$$C \frac{dn_i(t)}{dt} = \sum_{j=1}^S T_{i,j} a_j(t) - \frac{n_i(t)}{R_i} + I_i$$



n_i - input voltage to the i th amplifier
ولتاژ ورودی به تقویت‌کننده‌ی i ام

a_i - output voltage of the i th amplifier
ولتاژ خروجی از تقویت‌کننده‌ی i ام

C - amplifier input capacitance
ظرفیت خازنی ورودی تقویت‌کننده

I_i - fixed input current to the i th amplifier
جریان ورودی ثابت به تقویت‌کننده‌ی i ام

با فرض تقارن در مدار، داریم: $T_{i,j} = T_{j,i}$

$$|T_{i,j}| = \frac{1}{R_{i,j}} \quad \frac{1}{R_i} = \frac{1}{\rho} + \sum_{j=1}^S \frac{1}{R_{i,j}} \quad n_i = f^{-1}(a_i) \quad a_i = f(n_i)$$

$f(n)$ مشخصه‌ی تقویت‌کننده است.

تابع انتقال تقویت‌کننده $a_i = f(n_i)$ یک تابع سیگموئید است (خودش و معکوسش صعودی است).



$$R_i C \frac{dn_i(t)}{dt} = \sum_{j=1}^S R_i T_{i,j} a_j(t) - n_i(t) + R_i I_i$$

Define:

$$\varepsilon = R_i C \quad w_{i,j} = R_i T_{i,j} \quad b_i = R_i I_i$$

$$\varepsilon \frac{dn_i(t)}{dt} = -n_i(t) + \sum_{j=1}^S w_{i,j} a_j(t) + b_i$$

Vector Form:

$$\varepsilon \frac{d\mathbf{n}(t)}{dt} = -\mathbf{n}(t) + \mathbf{W}\mathbf{a}(t) + \mathbf{b}$$

$$\mathbf{a}(t) = \mathbf{f}(\mathbf{n}(t))$$

مدل هاپفیلد

قالب شبکه

NETWORK FORMAT

با ضرب طرفین معادله در R_i داریم:

$$R_i C \frac{dn_i(t)}{dt} = \sum_{j=1}^S R_i T_{i,j} a_j(t) - n_i(t) + R_i I_i$$

Define:

با تعریف:

$$\varepsilon = R_i C \quad w_{i,j} = R_i T_{i,j} \quad b_i = R_i I_i$$

به معادله‌ی زیر در فرم استاندارد شبکه‌های عصبی می‌رسیم:

$$\varepsilon \frac{dn_i(t)}{dt} = -n_i(t) + \sum_{j=1}^S w_{i,j} a_j(t) + b_i$$

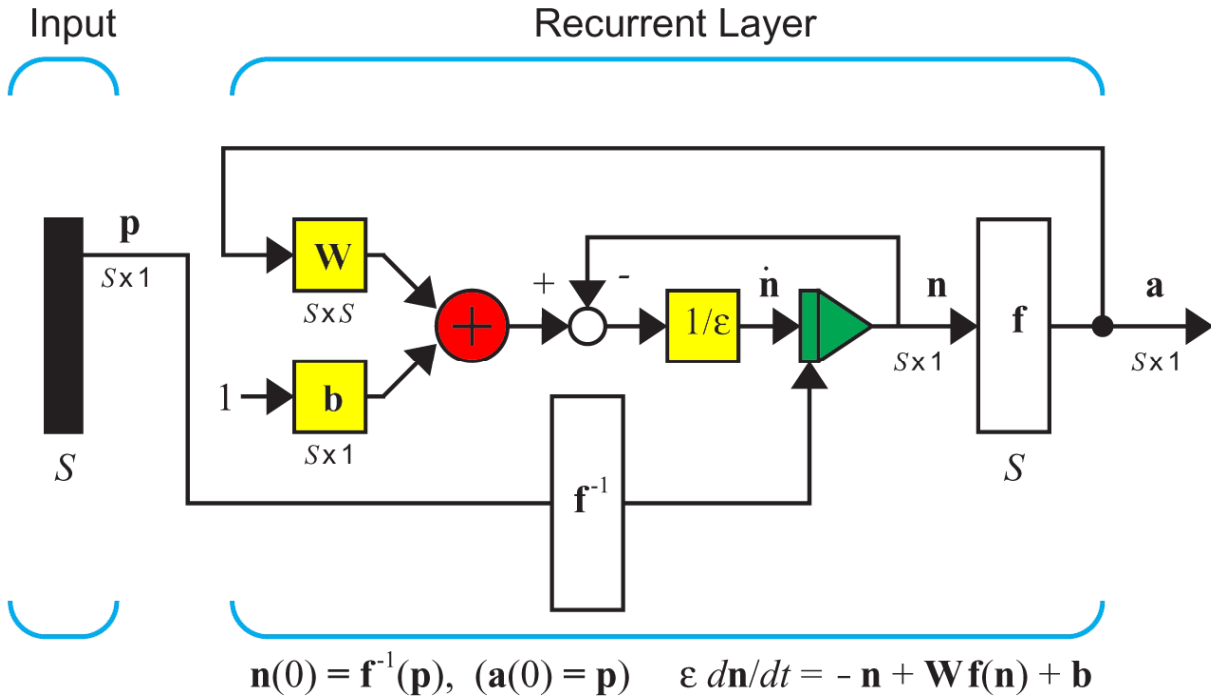
Vector Form:

فرم برداری:

$$\varepsilon \frac{d\mathbf{n}(t)}{dt} = -\mathbf{n}(t) + \mathbf{W}\mathbf{a}(t) + \mathbf{b}$$

که در آن:

$$\mathbf{a}(t) = \mathbf{f}(\mathbf{n}(t))$$

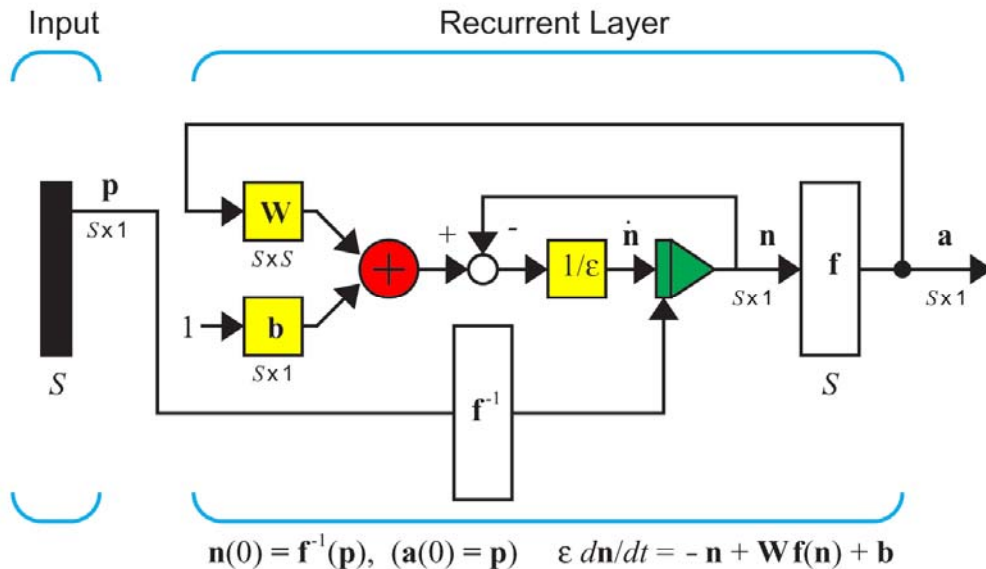


مدل هاپفیلد

شبکه‌ی هاپفیلد

HOPFIELD NETWORK

بازنمایی شبکه‌ی هاپفیلد پایه (متشکل از مدارهای تقویت‌کننده‌ی عملیاتی) در قالب شبکه‌های عصبی استاندارد:



بردار ورودی p مشخص، خروجی اولیه‌ی شبکه می‌باشد.

* این شکل از شبکه‌های هاپفیلد در شبکه‌های حافظه انجمنی استفاده می‌شود.

شبکه‌ی هاپفیلد

۲

تابع
لیاپانوف



$$V(\mathbf{a}) = -\frac{1}{2}\mathbf{a}^T \mathbf{W} \mathbf{a} + \sum_{i=1}^S \left\{ \int_0^{a_i} f^{-1}(u) du \right\} - \mathbf{b}^T \mathbf{a}$$

تابع لیاپانوف

تابع لیاپانوف برای شبکه‌ی هاپفیلد

LYAPUNOV FUNCTION

استفاده از قضیه‌ی پایداری لیاپانوف برای تحلیل شبکه‌های بازگشتی، یکی از دستاوردهای کلیدی هاپفیلد است.

نشان می‌دهیم که چگونه می‌توان از «قضیه‌ی تغییرناپذیری لاسال» برای شبکه‌ی هاپفیلد استفاده نمود.
ابتدا باید تابع لیاپانوف انتخاب شود.
هاپفیلد، تابع زیر را به عنوان تابع لیاپانوف پیشنهاد کرد:

$$V(\mathbf{a}) = -\frac{1}{2} \mathbf{a}^T \mathbf{W} \mathbf{a} + \sum_{i=1}^S \left\{ \int_0^{a_i} f^{-1}(u) du \right\} - \mathbf{b}^T \mathbf{a}$$

* انتخاب این تابع خاص، به عنوان تابع لیاپانوف، یکی از دستاوردهای مهم هاپفیلد است.



First Term:

$$\frac{d}{dt} \left\{ -\frac{1}{2} \mathbf{a}^T \mathbf{W} \mathbf{a} \right\} = -\frac{1}{2} \nabla [\mathbf{a}^T \mathbf{W} \mathbf{a}]^T \frac{d\mathbf{a}}{dt} = -[\mathbf{W} \mathbf{a}]^T \frac{d\mathbf{a}}{dt} = -\mathbf{a}^T \mathbf{W} \frac{d\mathbf{a}}{dt}$$

Second Term:

$$\frac{d}{dt} \left\{ \int_0^{a_i} f^{-1}(u) du \right\} = \frac{d}{da_i} \left\{ \int_0^{a_i} f^{-1}(u) du \right\} \frac{da_i}{dt} = f^{-1}(a_i) \frac{da_i}{dt} = n_i \frac{da_i}{dt}$$

$$\frac{d}{dt} \left[\sum_{i=1}^S \left\{ \int_0^{a_i} f^{-1}(u) du \right\} \right] = \mathbf{n}^T \frac{d\mathbf{a}}{dt}$$

Third Term:

$$\frac{d}{dt} \{ -\mathbf{b}^T \mathbf{a} \} = -\nabla [\mathbf{b}^T \mathbf{a}]^T \frac{d\mathbf{a}}{dt} = -\mathbf{b}^T \frac{d\mathbf{a}}{dt}$$

تابع لیاپانوف

مشتقات تک تک جملات تابع لیاپانوف برای شبکه‌ی هاپفیلد

INDIVIDUAL DERIVATIVES

برای استفاده از قضیه‌ی لاسال، باید مشتق $V(\mathbf{a})$ را محاسبه کنیم. هر یک از جملات $V(\mathbf{a})$ را جداگانه بررسی می‌کنیم:

First Term:

جمله‌ی اول:

$$\frac{d}{dt} \left\{ -\frac{1}{2} \mathbf{a}^T \mathbf{W} \mathbf{a} \right\} = -\frac{1}{2} \nabla [\mathbf{a}^T \mathbf{W} \mathbf{a}]^T \frac{d\mathbf{a}}{dt} = -[\mathbf{W} \mathbf{a}]^T \frac{d\mathbf{a}}{dt} = -\mathbf{a}^T \mathbf{W} \frac{d\mathbf{a}}{dt}$$

Second Term:

جمله‌ی دوم: شامل مجموع چند انتگرال؛
با در نظر گرفتن یکی از انتگرال‌ها داریم:

$$\frac{d}{dt} \left\{ \int_0^{a_i} f^{-1}(u) du \right\} = \frac{d}{da_i} \left\{ \int_0^{a_i} f^{-1}(u) du \right\} \frac{da_i}{dt} = f^{-1}(a_i) \frac{da_i}{dt} = n_i \frac{da_i}{dt}$$

$$\frac{d}{dt} \left[\sum_{i=1}^S \left\{ \int_0^{a_i} f^{-1}(u) du \right\} \right] = \mathbf{n}^T \frac{d\mathbf{a}}{dt}$$

مجموع مشتقات جمله‌ی دوم:

Third Term:

جمله‌ی سوم:

$$\frac{d}{dt} \{ -\mathbf{b}^T \mathbf{a} \} = -\nabla [\mathbf{b}^T \mathbf{a}]^T \frac{d\mathbf{a}}{dt} = -\mathbf{b}^T \frac{d\mathbf{a}}{dt}$$



$$\frac{d}{dt}V(\mathbf{a}) = -\mathbf{a}^T \mathbf{W} \frac{d\mathbf{a}}{dt} + \mathbf{n}^T \frac{d\mathbf{a}}{dt} - \mathbf{b}^T \frac{d\mathbf{a}}{dt} = [-\mathbf{a}^T \mathbf{W} + \mathbf{n}^T - \mathbf{b}^T] \frac{d\mathbf{a}}{dt}$$

From the system equations we know:

$$[-\mathbf{a}^T \mathbf{W} + \mathbf{n}^T - \mathbf{b}^T] = -\varepsilon \left[\frac{d\mathbf{n}(t)}{dt} \right]^T$$

So the derivative can be written:

$$\begin{aligned} \frac{d}{dt}V(\mathbf{a}) &= -\varepsilon \left[\frac{d\mathbf{n}(t)}{dt} \right]^T \frac{d\mathbf{a}}{dt} = -\varepsilon \sum_{i=1}^S \left(\frac{dn_i}{dt} \right) \left(\frac{da_i}{dt} \right) = -\varepsilon \sum_{i=1}^S \left(\frac{dn_i}{dt} \right) \left(\frac{da_i}{dt} \right) \\ &= -\varepsilon \sum_{i=1}^S \left(\frac{d}{da_i} [f^{-1}(a_i)] \right) \left(\frac{da_i}{dt} \right)^2 \end{aligned}$$

If $\frac{d}{da_i} [f^{-1}(a_i)] > 0$ then $\frac{d}{dt}V(\mathbf{a}) \leq 0$

تابع لیاپانوف

مشتقات کامل تابع لیاپانوف برای شبکه‌ی هاپفیلد

COMPLETE LYAPUNOV DERIVATIVE

پس مشتق $V(\mathbf{a})$ به صورت زیر می‌باشد:

$$\frac{d}{dt}V(\mathbf{a}) = -\mathbf{a}^T \mathbf{W} \frac{d\mathbf{a}}{dt} + \mathbf{n}^T \frac{d\mathbf{a}}{dt} - \mathbf{b}^T \frac{d\mathbf{a}}{dt} = [-\mathbf{a}^T \mathbf{W} + \mathbf{n}^T - \mathbf{b}^T] \frac{d\mathbf{a}}{dt}$$

از معادلات سیستم داریم: From the system equations we know:

$$[-\mathbf{a}^T \mathbf{W} + \mathbf{n}^T - \mathbf{b}^T] = -\varepsilon \left[\frac{d\mathbf{n}(t)}{dt} \right]^T$$

پس می‌توان مشتق را به صورت زیر بازنویسی کرد: So the derivative can be written:

$$\begin{aligned} \frac{d}{dt}V(\mathbf{a}) &= -\varepsilon \left[\frac{d\mathbf{n}(t)}{dt} \right]^T \frac{d\mathbf{a}}{dt} = -\varepsilon \sum_{i=1}^S \left(\frac{dn_i}{dt} \right) \left(\frac{da_i}{dt} \right) = -\varepsilon \sum_{i=1}^S \left(\frac{dn_i}{dt} \right) \left(\frac{da_i}{dt} \right) \\ &= -\varepsilon \sum_{i=1}^S \left(\frac{d}{da_i} [f^{-1}(a_i)] \right) \left(\frac{da_i}{dt} \right)^2 \end{aligned}$$

وقتی f^{-1} تابعی صعودی است.

$$\text{If } \frac{d}{da_i} [f^{-1}(a_i)] > 0 \quad \text{then} \quad \frac{d}{dt}V(\mathbf{a}) \leq 0$$

پس اگر $f^{-1}(\mathbf{a})$ یک تابع صعودی باشد، $dV(\mathbf{a})/dt$ یک تابع نیمه‌معین منفی است $\Leftrightarrow V(\mathbf{a})$ یک تابع مناسب لیاپانوف می‌باشد.



$$Z = \{\mathbf{a}: dV(\mathbf{a})/dt = 0, \mathbf{a} \text{ in the closure of } G\}$$

$$\frac{d}{dt}V(\mathbf{a}) = -\epsilon \sum_{i=1}^S \left(\frac{d}{da_i} [f^{-1}(a_i)] \right) \left(\frac{da_i}{dt} \right)^2$$

This will be zero only if the neuron outputs are not changing:

$$\frac{d\mathbf{a}}{dt} = \mathbf{0}$$

Therefore, the system energy is not changing only at the equilibrium points of the circuit. Thus, all points in Z are potential attractors:

$$L = Z$$

تابع لیاپانوف

مجموعه‌های تغییرناپذیر

INVARIANT SETS

به منظور استفاده از قضیه‌ی تغییرناپذیری لاسال برای تعیین نقاط تعادل در شبکه‌ی هاپفیلد، ابتدا مجموعه‌ی Z را می‌یابیم:

$$Z = \{\mathbf{a}: dV(\mathbf{a})/dt = 0, \mathbf{a} \text{ in the closure of } G\}$$

(همه‌ی نقاطی که مشتق تابع لیاپانوف در آن صفر است: فرض می‌کنیم G شامل کل \mathbb{R}^2 باشد.)

$$\frac{d}{dt}V(\mathbf{a}) = -\varepsilon \sum_{i=1}^S \left(\frac{d}{da_i} [f^{-1}(a_i)] \right) \left(\frac{da_i}{dt} \right)^2$$

مقدار مشتق $V(\mathbf{a})$ در صورتی صفر می‌شود که مشتق خروجی همه‌ی نرون‌ها برابر با صفر شود.

This will be zero only if the neuron outputs are not changing:

$$\frac{d\mathbf{a}}{dt} = \mathbf{0}$$

صفر شدن مشتقات در صورتی امکان دارد که خروجی‌های نرون‌ها بدون تغییر باشند.

Therefore, the system energy is not changing only at the equilibrium points of the circuit. Thus, all points in Z are potential attractors:

این نقاط در مکان‌هایی قرار دارند که انرژی سیستم تغییر نمی‌کند؛ پس L (بزرگ‌ترین مجموعه‌ی تغییرناپذیر Z) می‌شود:

$$L = Z$$

بنابراین همه‌ی نقاط Z به طور بالقوه جزء نقاط جذب هستند.



$$a = f(n) = \frac{2}{\pi} \tan^{-1} \left(\frac{\gamma \pi n}{2} \right) \quad n = \frac{2}{\gamma \pi} \tan \left(\frac{\pi}{2} a \right)$$

$$\left. \begin{array}{l} R_{1,2} = R_{2,1} = 1 \\ T_{1,2} = T_{2,1} = 1 \end{array} \right\} \mathbf{W} = \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix}$$

$$\varepsilon = R_i C = 1$$

$$\gamma = 1.4$$

$$\left. \begin{array}{l} I_1 = I_2 = 0 \end{array} \right\} \mathbf{b} = \begin{bmatrix} 0 \\ 0 \end{bmatrix}$$

تابع لیاپانوف

مثال

EXAMPLE

سیستمی را مورد بررسی قرار می‌دهیم که دارای مشخصه‌ی یک تقویت‌کننده است:

$$a = f(n) = \frac{2}{\pi} \tan^{-1} \left(\frac{\gamma \pi n}{2} \right) \quad n = \frac{2}{\gamma \pi} \tan \left(\frac{\pi}{2} a \right)$$

$$\left. \begin{array}{l} R_{1,2} = R_{2,1} = 1 \\ T_{1,2} = T_{2,1} = 1 \end{array} \right\} \mathbf{W} = \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix}$$

ماتریس وزن

دو تقویت‌کننده را در نظر می‌گیریم که خروجی هر یک به ورودی دیگری از طریق یک مقاومت متصل باشد:

$$\varepsilon = R_i C = 1$$

اگر خازن ورودی تقویت‌کننده نیز برابر 1 قرار داده شود، داریم:

$$\gamma = 1.4$$

قرار می‌دهیم:

$$\left. \begin{array}{l} I_1 = I_2 = 0 \end{array} \right\} \mathbf{b} = \begin{bmatrix} 0 \\ 0 \end{bmatrix}$$

بایاس

پس:



$$V(\mathbf{a}) = -\frac{1}{2}\mathbf{a}^T \mathbf{W} \mathbf{a} + \sum_{i=1}^S \left\{ \int_0^{a_i} f^{-1}(u) du \right\} - \mathbf{b}^T \mathbf{a}$$

$$-\frac{1}{2}\mathbf{a}^T \mathbf{W} \mathbf{a} = -\frac{1}{2} \begin{bmatrix} a_1 & a_2 \end{bmatrix} \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix} \begin{bmatrix} a_1 \\ a_2 \end{bmatrix} = -a_1 a_2$$

$$\int_0^{a_i} f^{-1}(u) du = \frac{2}{\gamma\pi} \int_0^{a_i} \tan\left(\frac{\pi}{2}u\right) du = \frac{2}{\gamma\pi} \left[-\log \left[\cos\left(\frac{\pi}{2}u\right) \right] \frac{2}{\pi} \right]_0^{a_i} = -\frac{4}{\gamma\pi^2} \log \left[\cos\left(\frac{\pi}{2}a_i\right) \right]$$

$$V(\mathbf{a}) = -a_1 a_2 - \frac{4}{1.4\pi^2} \left[\log \left\{ \cos\left(\frac{\pi}{2}a_1\right) \right\} + \log \left\{ \cos\left(\frac{\pi}{2}a_2\right) \right\} \right]$$

تابع لیاپانوف

مثال (تابع لیاپانوف)

EXAMPLE LYAPUNOV FUNCTION

$$V(\mathbf{a}) = -\frac{1}{2}\mathbf{a}^T \mathbf{W} \mathbf{a} + \sum_{i=1}^S \left\{ \int_0^{a_i} f^{-1}(u) du \right\} - \mathbf{b}^T \mathbf{a} \quad \text{تابع لیاپانوف:}$$

جمله‌ی سوم صفر است
زیرا بایاس صفر است.

جمله‌ی اول:

$$-\frac{1}{2}\mathbf{a}^T \mathbf{W} \mathbf{a} = -\frac{1}{2} \begin{bmatrix} a_1 & a_2 \end{bmatrix} \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix} \begin{bmatrix} a_1 \\ a_2 \end{bmatrix} = -a_1 a_2$$

جزء i -ام جمله‌ی دوم به صورت زیر است:

$$\int_0^{a_i} f^{-1}(u) du = \frac{2}{\gamma\pi} \int_0^{a_i} \tan\left(\frac{\pi}{2}u\right) du = \frac{2}{\gamma\pi} \left[-\log \left[\cos\left(\frac{\pi}{2}u\right) \right] \frac{2}{\pi} \right]_0^{a_i} = -\frac{4}{\gamma\pi^2} \log \left[\cos\left(\frac{\pi}{2}a_i\right) \right]$$

بنابراین، برای تابع لیاپانوف داریم:

$$V(\mathbf{a}) = -a_1 a_2 - \frac{4}{1.4\pi^2} \left[\log \left\{ \cos\left(\frac{\pi}{2}a_1\right) \right\} + \log \left\{ \cos\left(\frac{\pi}{2}a_2\right) \right\} \right]$$



$$\frac{d\mathbf{n}}{dt} = -\mathbf{n} + \mathbf{W}\mathbf{f}(\mathbf{n}) = -\mathbf{n} + \mathbf{W}\mathbf{a}$$

$$dn_1/dt = a_2 - n_1$$

$$dn_2/dt = a_1 - n_2$$

$$a_1 = \frac{2}{\pi} \tan^{-1} \left(\frac{1.4\pi}{2} n_1 \right)$$

$$a_2 = \frac{2}{\pi} \tan^{-1} \left(\frac{1.4\pi}{2} n_2 \right)$$

تابع لیاپانوف

مثال (معادلات شبکه)

EXAMPLE NETWORK EQUATIONS

حال، معادله‌ی شبکه را می‌نویسیم. با $\varepsilon = 1$ و $\mathbf{b} = 0$ معادله‌ی شبکه به صورت زیر خواهد بود:

$$\frac{d\mathbf{n}}{dt} = -\mathbf{n} + \mathbf{W}\mathbf{f}(\mathbf{n}) = -\mathbf{n} + \mathbf{W}\mathbf{a}$$

با جایگزینی ماتریس وزن‌ها در این عبارت به دو معادله‌ی زیر می‌رسیم:



$$dn_1/dt = a_2 - n_1$$

$$dn_2/dt = a_1 - n_2$$

خروجی نرون‌ها عبارت است از:

$$a_1 = \frac{2}{\pi} \tan^{-1} \left(\frac{1.4\pi}{2} n_1 \right)$$

$$a_2 = \frac{2}{\pi} \tan^{-1} \left(\frac{1.4\pi}{2} n_2 \right)$$





تابع لیاپانوف



مثال (تابع لیاپانوف و خط سیر)

LYAPUNOV FUNCTION AND TRAJECTORY

نمودار کانتوری و یک خط سیر نمونه
(در ارتباط با این تابع لیاپانوف)





این سیستم دارای دو جذب‌کننده می‌باشد (یکی در پایین سمت چپ و دیگری در بالا سمت راست)




تابع لیاپانوف

مثال (پاسخ زمانی)


TIME RESPONSE

پاسخ زمانی تابع لیاپانوف:
این تابع تا رسیدن به نقطه‌ی تعادل
به صورت پیوسته کاهش می‌یابد.



تابع لیپانوف

مثال (همگرایی به نقطه‌ی زینی)

CONVERGENCE TO A SADDLE POINT

این سیستم دارای یک نقطه‌ی تعادل زینی در مبدأ است.

اگر شبکه در هر مکانی روی خط قطری واصل بین گوشه‌های چپ بالا و راست پایین مقداردهی آغازین شود، راه‌حل به مبدأ همگرا می‌شود.

هر حالت آغازینی که روی این خط واقع نشود، به یکی از راه‌حل‌های چپ پایین یا راست بالا همگرا می‌شود.

* راه‌حل واقع در مبدأ یک نقطه‌ی زینی برای تابع لیپانوف است و می‌نیم محلی نیست.

nnd18hn

File Edit View Insert Tools Desktop Window Help

Neural Network DESIGN Hopfield Network

Lyapunov Function

Lyapunov Function

Click in the left graph to simulate the Hopfield network.

Change the weights, biases, and gain then click [Update] to change the network.

$$W = \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix}$$

$$b = \begin{bmatrix} 0 \\ 0 \end{bmatrix}$$

Finite Gain: **Finite Gain Value:** **1.4**
 Infinite Gain: **0.0** **2.0**

Update

Contents

Close

Chapter 18



>> nnd18hn

Hopfield Attractors



The potential attractors of the Hopfield network satisfy:

$$\frac{d\mathbf{a}}{dt} = \mathbf{0}$$

How are these points related to the minima of $V(\mathbf{a})$? The minima must satisfy:

$$\nabla V = \left[\frac{\partial V}{\partial a_1} \quad \frac{\partial V}{\partial a_2} \quad \cdots \quad \frac{\partial V}{\partial a_S} \right]^T = \mathbf{0}$$

Where the Lyapunov function is given by:

$$V(\mathbf{a}) = -\frac{1}{2} \mathbf{a}^T \mathbf{W} \mathbf{a} + \sum_{i=1}^S \left\{ \int_0^{a_i} f^{-1}(u) du \right\} - \mathbf{b}^T \mathbf{a}$$

تابع لیاپانوف

جذب‌کننده‌های هاپفیلد

HOPFIELD ATTRACTORS

جذب‌کننده‌های بالقوه‌ی شبکه‌ی هاپفیلد، شرط زیر را ارضا می‌کنند:

The potential attractors of the Hopfield network satisfy:

$$\frac{d\mathbf{a}}{dt} = \mathbf{0}$$

ارتباط نقاط جذب‌کننده با می‌نیم‌های تابع لیاپانوف: نقاط می‌نیم باید شرط نقطه‌ی ایستادن را ارضا کنند:

How are these points related to the minima of $V(\mathbf{a})$? The minima must satisfy:

$$\nabla V = \left[\frac{\partial V}{\partial a_1} \quad \frac{\partial V}{\partial a_2} \quad \dots \quad \frac{\partial V}{\partial a_S} \right]^T = \mathbf{0}$$

(نقطه‌ی ایستادن \equiv مشتق مساوی صفر)

که در آن تابع لیاپانوف به‌صورت زیر است:

Where the Lyapunov function is given by:

$$V(\mathbf{a}) = -\frac{1}{2} \mathbf{a}^T \mathbf{W} \mathbf{a} + \sum_{i=1}^S \left\{ \int_0^{a_i} f^{-1}(u) du \right\} - \mathbf{b}^T \mathbf{a}$$



Using previous results, we can show that:

$$\nabla V(\mathbf{a}) = [-\mathbf{W}\mathbf{a} + \mathbf{n} - \mathbf{b}] = -\varepsilon \left[\frac{d\mathbf{n}(t)}{dt} \right]$$

The i th element of the gradient is therefore:

$$\frac{\partial}{\partial a_i} V(\mathbf{a}) = -\varepsilon \frac{dn_i}{dt} = -\varepsilon \frac{d}{dt} ([f^{-1}(a_i)]) = -\varepsilon \frac{d}{da_i} [f^{-1}(a_i)] \frac{da_i}{dt}$$

Since the transfer function and its inverse are monotonic increasing:

$$\frac{d}{da_i} [f^{-1}(a_i)] > 0$$

All points for which $\frac{d\mathbf{a}(t)}{dt} = \mathbf{0}$ will also satisfy $\nabla V(\mathbf{a}) = \mathbf{0}$

Therefore all attractors will be stationary points of $V(\mathbf{a})$.

تابع لیاپانوف

جذب‌کننده‌های هاپفیلد

HOPFIELD ATTRACTORS

از نتایج قبلی می‌توان نشان داد: Using previous results, we can show that:

$$\nabla V(\mathbf{a}) = [-\mathbf{W}\mathbf{a} + \mathbf{n} - \mathbf{b}] = -\varepsilon \left[\frac{d\mathbf{n}(t)}{dt} \right]$$

پس عنصر i -ام گرادیان می‌شود:

The i th element of the gradient is therefore:

$$\frac{\partial}{\partial a_i} V(\mathbf{a}) = -\varepsilon \frac{dn_i}{dt} = -\varepsilon \frac{d}{dt} (f^{-1}(a_i)) = -\varepsilon \frac{d}{da_i} [f^{-1}(a_i)] \frac{da_i}{dt}$$

چون تابع انتقال و معکوس آن یکنوای صعودی هستند، پس:

Since the transfer function and its inverse are monotonic increasing:

$$\frac{d}{da_i} [f^{-1}(a_i)] > 0$$

این دلالت دارد بر اینکه در همه‌ی نقاطی که $da/dt = \mathbf{0}$ است، گرادیان $V(\mathbf{a})$ هم مساوی صفر است.

All points for which $\frac{d\mathbf{a}(t)}{dt} = \mathbf{0}$ will also satisfy $\nabla V(\mathbf{a}) = \mathbf{0}$

پس همه‌ی جذب‌کننده‌ها، نقاط ایستادن $V(\mathbf{a})$ نیز هستند.

Therefore all attractors will be stationary points of $V(\mathbf{a})$.

* در صورت خطی بودن $f^{-1}(\mathbf{a})$ داریم: $da/dt = -\alpha \nabla V(\mathbf{a})$ ، پس پاسخ شبکه‌ی هاپفیلد، پاسخی از نوع بیشترین کاهش است. پس در ناحیه‌ای که $f^{-1}(\mathbf{a})$ تقریباً خطی است، راه‌حل شبکه تقریباً از بیشترین کاهش است.


شبکه‌ی هاپفیلد

۳

اثر
بهره



$$a = f(n) = \frac{2}{\pi} \tan^{-1} \left(\frac{\gamma \pi n}{2} \right)$$



اثر بهره


اثر بهره در تابع انتقال

EFFECT OF GAIN

تابع لیاپانوف هاپفیلد را می‌توان در مواردی که میزان بهره‌ی تقویت‌کنندگی (γ) بزرگ باشد، ساده‌تر نمود:

$$a = f(n) = \frac{2}{\pi} \tan^{-1} \left(\frac{\gamma \pi n}{2} \right)$$

γ شیب منحنی در $n = 0$ را تعیین می‌کند. (افزایش γ تا بی‌نهایت، $f(n)$ را به تابع علامت (sign) تبدیل می‌کند.)




Lyapunov Function



$$V(\mathbf{a}) = -\frac{1}{2}\mathbf{a}^T \mathbf{W} \mathbf{a} + \sum_{i=1}^S \left\{ \int_0^{a_i} f^{-1}(u) du \right\} - \mathbf{b}^T \mathbf{a} \quad f^{-1}(u) = \frac{2}{\gamma\pi} \tan\left(\frac{\pi u}{2}\right)$$

$$\int_0^{a_i} f^{-1}(u) du = \frac{2}{\gamma\pi} \left[\frac{2}{\pi} \log\left(\cos\left(\frac{\pi a_i}{2}\right)\right) \right] = -\frac{4}{\gamma\pi^2} \log\left[\cos\left(\frac{\pi a_i}{2}\right)\right]$$

$$-\frac{4}{\gamma\pi^2} \log\left[\cos\left(\frac{\pi a}{2}\right)\right]$$



اثر بهره

اثر بهره در تابع لیاپانوف

LYAPUNOV FUNCTION

با در نظر گرفتن شکل کلی تابع لیاپانوف هاپفیلد داریم:


$$V(\mathbf{a}) = -\frac{1}{2}\mathbf{a}^T \mathbf{W} \mathbf{a} + \sum_{i=1}^S \left\{ \int_0^{a_i} f^{-1}(u) du \right\} - \mathbf{b}^T \mathbf{a}$$

$$f^{-1}(u) = \frac{2}{\gamma\pi} \tan\left(\frac{\pi u}{2}\right)$$

جمله‌ی دوم تابع لیاپانوف به صورت زیر است:

$$\int_0^{a_i} f^{-1}(u) du = \frac{2}{\gamma\pi} \left[\frac{2}{\pi} \log\left(\cos\left(\frac{\pi a_i}{2}\right)\right) \right] = -\frac{4}{\gamma\pi^2} \log\left[\cos\left(\frac{\pi a_i}{2}\right)\right]$$

$$-\frac{4}{\gamma\pi^2} \log\left[\cos\left(\frac{\pi a}{2}\right)\right]$$



تابع این جمله با افزایش γ مسطح‌تر شده و به تابع صفر نزدیک‌تر می‌شود.

⇐

با رسیدن γ به بی‌نهایت، انتگرال جمله‌ی دوم در تابع لیاپانوف در محدوده‌ی $-1 < a_i < 1$ به صفر نزدیک می‌شود.

⇐

می‌توان از این جمله صرف‌نظر کرد.



As $\gamma \rightarrow \infty$ the Lyapunov function reduces to:

$$V(\mathbf{a}) = -\frac{1}{2}\mathbf{a}^T \mathbf{W} \mathbf{a} - \mathbf{b}^T \mathbf{a}$$

The high gain Lyapunov function is quadratic:

$$V(\mathbf{a}) = -\frac{1}{2}\mathbf{a}^T \mathbf{W} \mathbf{a} - \mathbf{b}^T \mathbf{a} = \frac{1}{2}\mathbf{a}^T \mathbf{A} \mathbf{a} + \mathbf{d}^T \mathbf{a} + c$$

where

$$\nabla^2 V(\mathbf{a}) = \mathbf{A} = -\mathbf{W} \quad \mathbf{d} = -\mathbf{b} \quad c = 0$$

اثر بهره

تابع لیاپانوف با بهره‌ی بالا

HIGH GAIN LYAPUNOV FUNCTION

وقتی γ به سمت بی‌نهایت میل کند، تابع لیاپانوف به صورت زیر فروکاسته می‌شود:

As $\gamma \rightarrow \infty$ the Lyapunov function reduces to:

$$V(\mathbf{a}) = -\frac{1}{2}\mathbf{a}^T \mathbf{W} \mathbf{a} - \mathbf{b}^T \mathbf{a}$$

پس تابع لیاپانوف با بهره‌ی بالا، یک تابع درجه دوم است.

The high gain Lyapunov function is quadratic:

$$V(\mathbf{a}) = -\frac{1}{2}\mathbf{a}^T \mathbf{W} \mathbf{a} - \mathbf{b}^T \mathbf{a} = \frac{1}{2}\mathbf{a}^T \mathbf{A} \mathbf{a} + \mathbf{d}^T \mathbf{a} + c$$

where

$$\nabla^2 V(\mathbf{a}) = \mathbf{A} = -\mathbf{W} \quad \mathbf{d} = -\mathbf{b} \quad c = 0$$



⇐ با استفاده از خواص تابع درجه دوم می‌توان عملکرد شبکه‌ی هاپفیلد را تشریح کرد.



$$\nabla^2 V(\mathbf{a}) = -\mathbf{W} = \begin{bmatrix} 0 & -1 \\ -1 & 0 \end{bmatrix} \quad |\nabla^2 V(\mathbf{a}) - \lambda \mathbf{I}| = \begin{vmatrix} -\lambda & -1 \\ -1 & -\lambda \end{vmatrix} = \lambda^2 - 1 = (\lambda + 1)(\lambda - 1)$$

$$\lambda_1 = -1 \quad \mathbf{z}_1 = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$$

$$\lambda_2 = 1 \quad \mathbf{z}_2 = \begin{bmatrix} 1 \\ -1 \end{bmatrix}$$



اثر بهره


مثال

EXAMPLE


$$\nabla^2 V(\mathbf{a}) = -\mathbf{W} = \begin{bmatrix} 0 & -1 \\ -1 & 0 \end{bmatrix} \quad |\nabla^2 V(\mathbf{a}) - \lambda \mathbf{I}| = \begin{vmatrix} -\lambda & -1 \\ -1 & -\lambda \end{vmatrix} = \lambda^2 - 1 = (\lambda + 1)(\lambda - 1)$$

$$\lambda_1 = -1 \quad \mathbf{z}_1 = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$$

$$\lambda_2 = 1 \quad \mathbf{z}_2 = \begin{bmatrix} 1 \\ -1 \end{bmatrix}$$



ماتریس هسی
 یک مقدار ویژه مثبت و یک مقدار ویژه منفی دارد
 \Leftarrow رویه‌ی تابع دارای یک نقطه‌ی زینی است.
 (این تابع می‌نیمم ندارد.)



با توجه به محدود شدن شبکه به یک ابرمکعب $\{\mathbf{a}: -1 < a_i < 1\}$ دو می‌نیمم در دو گوشه‌ی آن داریم: $\mathbf{a} = \begin{bmatrix} -1 \\ -1 \end{bmatrix}$, $\mathbf{a} = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$
 * وقتی γ خیلی کوچک است، یک نقطه‌ی می‌نیمم در مبدأ وجود دارد.

* با افزایش γ دو نقطه‌ی می‌نیمم از مبدأ به سمت گوشه‌ها حرکت می‌کند. مثلاً برای $\gamma = 1.4$ داریم: $\mathbf{a} = \begin{bmatrix} -0.57 \\ -0.57 \end{bmatrix}$, $\mathbf{a} = \begin{bmatrix} 0.57 \\ 0.57 \end{bmatrix}$

اثر بهره

می‌نیمم‌های بهره-بالا


HIGH-GAIN MINIMUMS

در حالت کلی شبکه‌ی هاپفیلد:

وقتی بیش از دو نرون در شبکه داشته باشیم،
می‌نیمم‌های بهره-بالا در گوشه‌های ابرمکعب

$$\{\mathbf{a} : -1 < a_i < 1\}$$

واقع می‌شوند.



شبکه‌ی هاپفیلد

۴

طراحی
شبکه‌ی
هاپفیلد



The Hopfield network will minimize the following Lyapunov function:

$$V(\mathbf{a}) = -\frac{1}{2}\mathbf{a}^T \mathbf{W} \mathbf{a} - \mathbf{b}^T \mathbf{a}$$

Choose the weight matrix \mathbf{W} and the bias vector \mathbf{b} so that V takes on the form of a function you want to minimize.

طراحی شبکه‌ی هاپفیلد

HOPFIELD DESIGN

شبکه‌ی هاپفیلد فاقد قاعده‌ی یادگیری است.
در واقع این شبکه آموزش داده نمی‌شود،
بلکه بر مبنای تابع لیاپانوف مورد استفاده برای تعیین ماتریس وزن‌ها طراحی می‌گردد.

The Hopfield network will minimize the following Lyapunov function:

$$V(\mathbf{a}) = -\frac{1}{2}\mathbf{a}^T \mathbf{W} \mathbf{a} - \mathbf{b}^T \mathbf{a}$$

Choose the weight matrix \mathbf{W} and the bias vector \mathbf{b} so that V takes on the form of a function you want to minimize.

ماتریس وزن \mathbf{W} و بردار بایاس \mathbf{b} را به گونه‌ای انتخاب می‌کنیم که تابع V که قصد می‌نیم‌سازی آن را داریم، شکل دهد.



تبدیل مسئله‌ی آموزش شبکه به یک مسئله‌ی می‌نیم‌سازی درجه دوم (چون شبکه‌ی هاپفیلد V را نیز می‌نیم می‌کند، به این ترتیب مسئله‌ی اصلی را هم حل می‌کند.)



Content-Addressable Memory - retrieves stored memories on the basis of part of the contents.

Prototype Patterns:

$$\{\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_Q\} \quad (\text{bipolar vectors})$$

Proposed Performance Index:

$$J(\mathbf{a}) = -\frac{1}{2} \sum_{q=1}^Q ([\mathbf{p}_q]^T \mathbf{a})^2$$

For orthogonal prototypes, if we evaluate the performance index at a prototype:

$$J(\mathbf{p}_j) = -\frac{1}{2} \sum_{q=1}^Q ([\mathbf{p}_q]^T \mathbf{p}_j)^2 = -\frac{1}{2} ([\mathbf{p}_j]^T \mathbf{p}_j)^2 = -\frac{S}{2}$$

$J(\mathbf{a})$ will be largest when \mathbf{a} is not close to any prototype pattern, and smallest when \mathbf{a} is equal to a prototype pattern.

حافظه‌ی آدرس‌پذیر با محتوا

CONTENT-ADDRESSABLE MEMORY

استفاده از شبکه‌ی هاپفیلد برای ساخت یک حافظه‌ی انجمنی \Leftarrow حافظه‌ی آدرس‌پذیر با محتوا (حافظه‌های ذخیره شده، بر اساس بخشی از محتوای آن بازیابی می‌شوند.)

می‌خواهیم این **الگوهای پروتوتایپ** را در یک شبکه‌ی هاپفیلد ذخیره کنیم:

فرض: $Q \ll S$

فضای حالت به اندازه‌ی کافی بزرگ است و به شرط توزیع متناسب الگوهای پروتوتایپ در این فضا، فواصل مناسبی نسبت به هم دارند و به هم نزدیک نیستند.

بردارهای دوقطبی S عضوی
Prototype Patterns:
 $\{\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_Q\}$ (bipolar vectors)

شاخص کارآیی پیشنهادی: **Proposed Performance Index:**

$$J(\mathbf{a}) = -\frac{1}{2} \sum_{q=1}^Q ([\mathbf{p}_q]^T \mathbf{a})^2$$

برای اینکه شبکه‌ی هاپفیلد قادر به یادآوری الگوهای پروتوتایپ باشد، این الگوها باید در می‌نیم تابع لیاپانوف واقع شوند.

چون تابع لیاپانوف با بهره‌ی بالا، یک تابع درجه دوم است، الگوهای پروتوتایپ باید می‌نیم این تابع باشند. اگر عناصر بردار \mathbf{a} به -1 و $+1$ محدود شود، این تابع در محل الگوهای پروتوتایپ می‌نیم می‌شود.

زمانی که یک الگوی ورودی به شبکه اعمال می‌شود، شبکه باید نزدیک‌ترین الگوی پروتوتایپ ذخیره شده نسبت به ورودی را به عنوان خروجی تولید کند. خروجی آغازین شبکه با الگوی ورودی مقارنه می‌شود. سپس خروجی شبکه باید به الگوی پروتوتایپی که در نزدیک‌ترین حالت نسبت به الگوی ورودی قرار دارد، همگرا شود. \Leftarrow الگوی پروتوتایپ باید در می‌نیم تابع لیاپانوف واقع باشد.

حافظه‌ی آدرس‌پذیر با محتوا

CONTENT-ADDRESSABLE MEMORY

برای الگوهای پروتوتایپ متعامد، اگر شاخص کارایی را در یک پروتوتایپ ارزیابی کنیم، خواهیم داشت:

For orthogonal prototypes, if we evaluate the performance index at a prototype:

$$J(\mathbf{p}_j) = -\frac{1}{2} \sum_{q=1}^Q ([\mathbf{p}_q] \mathbf{p}_j)^2 = -\frac{1}{2} ([\mathbf{p}_j] \mathbf{p}_j)^2 = -\frac{S}{2}$$

← تعامد
← همه‌ی عناصر ±1

$J(\mathbf{a})$ will be largest when \mathbf{a} is not close to any prototype pattern, and smallest when \mathbf{a} is equal to a prototype pattern.

اگر شاخص کارایی را در یک الگوی تصادفی ورودی \mathbf{a} ارزیابی کنیم که تا حد امکان از الگوهای پروتوتایپ دور است، داریم: — عبارت داخل \sum حاوی ضرب داخلی بین یک الگوی پروتوتایپ و بردار ورودی است.

— در صورتی که ورودی به هیچ‌یک از الگوهای پروتوتایپ نزدیک نباشد، آن‌گاه کلیه‌ی جملات این مجموع کوچک خواهند بود.



$J(\mathbf{a})$ بزرگ‌ترین مقدار خودش را زمانی دارد که \mathbf{a} به هیچ الگوی پروتوتایپی نزدیک نباشد.

$J(\mathbf{a})$ کوچک‌ترین مقدار خودش را زمانی دارد که \mathbf{a} با یک الگوی پروتوتایپ مساوی باشد.



پس یک تابع درجه دوم در اختیار داریم که با دقت مناسبی کارایی حافظه‌ی آدرس‌پذیر با محتوا را تعیین می‌کند.

← تابع لیاپانوف V معادل با شاخص کارایی درجه دوم J است.



If we use the supervised Hebb rule to compute the weight matrix:

$$\mathbf{W} = \sum_{q=1}^Q \mathbf{p}_q (\mathbf{p}_q)^T \quad \mathbf{b} = \mathbf{0}$$

the Lyapunov function will be:

$$V(\mathbf{a}) = -\frac{1}{2} \mathbf{a}^T \mathbf{W} \mathbf{a} = -\frac{1}{2} \mathbf{a}^T \left[\sum_{q=1}^Q \mathbf{p}_q (\mathbf{p}_q)^T \right] \mathbf{a} = -\frac{1}{2} \sum_{q=1}^Q \mathbf{a}^T \mathbf{p}_q (\mathbf{p}_q)^T \mathbf{a}$$

This can be rewritten:

$$V(\mathbf{a}) = -\frac{1}{2} \sum_{q=1}^Q [(\mathbf{p}_q)^T \mathbf{a}]^2 = J(\mathbf{a})$$

Therefore the Lyapunov function is equal to our performance index for the content addressable memory.

حافظه‌ی آدرس‌پذیر با محتوا

قاعده‌ی هب

HEBB RULE

حال باید ماتریس وزن \mathbf{W} و بردار بایاس \mathbf{b} را تعیین کنیم.
اگر از قاعده‌ی هب بانظارت برای محاسبه‌ی ماتریس وزن استفاده کنیم، داریم:

If we use the supervised Hebb rule to compute the weight matrix:

$$\mathbf{W} = \sum_{q=1}^Q \mathbf{p}_q (\mathbf{p}_q)^T \quad \mathbf{b} = \mathbf{0}$$

the Lyapunov function will be: آن‌گاه تابع لیاپانوف خواهد بود:

$$V(\mathbf{a}) = -\frac{1}{2} \mathbf{a}^T \mathbf{W} \mathbf{a} = -\frac{1}{2} \mathbf{a}^T \left[\sum_{q=1}^Q \mathbf{p}_q (\mathbf{p}_q)^T \right] \mathbf{a} = -\frac{1}{2} \sum_{q=1}^Q \mathbf{a}^T \mathbf{p}_q (\mathbf{p}_q)^T \mathbf{a}$$

This can be rewritten: که می‌تواند به صورت زیر بازنویسی شود:

$$V(\mathbf{a}) = -\frac{1}{2} \sum_{q=1}^Q [(\mathbf{p}_q)^T \mathbf{a}]^2 = J(\mathbf{a})$$

پس تابع لیاپانوف مساوی با شاخص کارایی ما برای حافظه‌ی آدرس‌پذیر با محتوا می‌باشد.

Therefore the Lyapunov function is equal to our performance index for the content addressable memory.

← خروجی شبکه‌ی هاپفیلد تمایل به همگرایی به الگوهای پروتوتایپ نخبیره شده دارد.

حافظه‌ی آدرس‌پذیر با محتوا

قاعده‌ی هب

HEBB RULE

قاعده‌ی هب بانظارت در صورت وجود همبستگی بالا بین الگوهای پروتوتایپ، عملکرد مناسبی ندارد. (در این موارد تکنیک شبه‌وارون پیشنهاد می‌شود.)

در بهترین حالت: الگوهای پروتوتایپ، متعامد هستند.
در این مورد هر یک از الگوهای پروتوتایپ در یک نقطه‌ی تعادل شبکه قرار خواهد داشت.

⇐ ممکن است شبکه به الگویی غیر از الگوهای پروتوتایپ همگرا شود.

قانون کلی در هنگام استفاده از قاعده‌ی هب:

تعداد الگوهای ذخیره شده نباید از **15%** تعداد نرون‌ها بیشتر باشد.

Hebb Rule Analysis



$$\mathbf{W} = \sum_{q=1}^Q \mathbf{p}_q (\mathbf{p}_q)^T$$

If we apply prototype \mathbf{p}_j to the network:

$$\mathbf{W}\mathbf{p}_j = \sum_{q=1}^Q \mathbf{p}_q (\mathbf{p}_q)^T \mathbf{p}_j = \mathbf{p}_j (\mathbf{p}_j)^T \mathbf{p}_j = S\mathbf{p}_j$$

Therefore each prototype is an eigenvector, and they have a common eigenvalue of S . The eigenspace for the eigenvalue $\lambda=S$ is therefore:

$$X = \text{span}\{\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_Q\}$$

An S -dimensional space of all vectors which can be written as linear combinations of the prototype vectors.

حافظه‌ی آدرس‌پذیر با محتوا

تحلیل قاعده‌ی هب

HEBB RULE ANALYSIS

فرض می‌کنیم الگوهای پروتوتایپ متعامد هستند و از قاعده‌ی هب برای محاسبه‌ی ماتریس وزن استفاده شود:

$$\mathbf{W} = \sum_{q=1}^Q \mathbf{p}_q (\mathbf{p}_q)^T$$

اگر بردار پروتوتایپ \mathbf{p}_j را به شبکه اعمال کنیم:

$$\mathbf{W} \mathbf{p}_j = \sum_{q=1}^Q \mathbf{p}_q (\mathbf{p}_q)^T \mathbf{p}_j = \mathbf{p}_j (\mathbf{p}_j)^T \mathbf{p}_j = S \mathbf{p}_j$$

همه‌ی عناصر ± 1 ← ← تعامد

Therefore each prototype is an eigenvector, and they have a common eigenvalue of S . The eigenspace for the eigenvalue $\lambda = S$ is therefore:

بنابراین، هر بردار پروتوتایپ یک بردار ویژه‌ی ماتریس وزن است و همگی آنها مقدار ویژه‌ی مشترک $\lambda = S$ را دارند. پس فضای ویژه برای این مقدار ویژه می‌شود:

$$X = \text{span}\{\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_Q\}$$

این یک فضای S -بعدی شامل همه‌ی بردارهایی است که می‌توان آنها را بر اساس ترکیب خطی بردارهای پروتوتایپ نوشت.

An S -dimensional space of all vectors which can be written as linear combinations of the prototype vectors.

← هر بردار پروتوتایپی که از ترکیب خطی بردارهای پروتوتایپ ایجاد شود، یک بردار ویژه است.

حافظه‌ی آدرس‌پذیر با محتوا

تحلیل قاعده‌ی هب

HEBB RULE ANALYSIS

هر بردار پروتوتایپی که از ترکیب خطی بردارهای پروتوتایپ ایجاد شود، یک بردار ویژه است.

$$\begin{aligned}
 \mathbf{W}\mathbf{a} &= \mathbf{W}\{\alpha_1\mathbf{p}_1 + \alpha_2\mathbf{p}_2 + \cdots + \alpha_Q\mathbf{p}_Q\} \\
 &= \{\alpha_1\mathbf{W}\mathbf{p}_1 + \alpha_2\mathbf{W}\mathbf{p}_2 + \cdots + \alpha_Q\mathbf{W}\mathbf{p}_Q\} \\
 &= \{\alpha_1S\mathbf{p}_1 + \alpha_2S\mathbf{p}_2 + \cdots + \alpha_QS\mathbf{p}_Q\} \\
 &= S\{\alpha_1\mathbf{p}_1 + \alpha_2\mathbf{p}_2 + \cdots + \alpha_Q\mathbf{p}_Q\} = S\mathbf{a}
 \end{aligned}$$

با فرض مستقل خطی بودن بردارهای پروتوتایپ، فضای ویژه‌ی مربوط به مقدار ویژه‌ی S ، $\lambda = S$ - بعدی است.



The entire input space can be divided into two disjoint sets:

$$R^S = X \cup X^\perp$$

where X^\perp is the orthogonal complement of X . For vectors \mathbf{a} in the orthogonal complement we have:

$$(\mathbf{p}_q)^T \mathbf{a} = 0, \quad q = 1, 2, \dots, Q$$

Therefore,

$$\mathbf{W}\mathbf{a} = \sum_{q=1}^Q \mathbf{p}_q (\mathbf{p}_q)^T \mathbf{a} = \sum_{q=1}^Q (\mathbf{p}_q \cdot 0) = \mathbf{0} = 0 \cdot \mathbf{a}$$

The eigenvalues of \mathbf{W} are S and 0 , with corresponding eigenspaces of X and X^\perp . For the Hessian matrix

$$\nabla^2 V = -\mathbf{W}$$

the eigenvalues are $-S$ and 0 , with the same eigenspaces.

حافظه‌ی آدرس‌پذیر با محتوا

تحلیل قاعده‌ی هب: فضای ویژه‌ی ماتریس وزن

WEIGHT MATRIX EIGENSPACE

کل فضای ورودی را می‌توان به دو مجموعه‌ی مجزا تقسیم کرد:

The entire input space can be divided into two disjoint sets:

$$R^S = X \cup X^\perp$$

(هر بردار از X^\perp بر هر بردار از X عمود است.)
 X^\perp متمم متعامد X است.

where X^\perp is the orthogonal complement of X . For vectors \mathbf{a} in the orthogonal complement we have:

$$(\mathbf{p}_q)^T \mathbf{a} = 0, \quad q = 1, 2, \dots, Q$$

برای هر بردار $\mathbf{a} \in X^\perp$ داریم:

Therefore,

پس اگر $\mathbf{a} \in X^\perp$ باشد، آن‌گاه داریم:

$$\mathbf{W}\mathbf{a} = \sum_{q=1}^Q \mathbf{p}_q (\mathbf{p}_q)^T \mathbf{a} = \sum_{q=1}^Q (\mathbf{p}_q \cdot 0) = \mathbf{0} = 0 \cdot \mathbf{a}$$

 $\leftarrow X^\perp$ یک فضای ویژه برای مقدار ویژه‌ی مکرر $\lambda = 0$ است.

The eigenvalues of \mathbf{W} are S and 0 , with corresponding eigenspaces of X and X^\perp . For the Hessian matrix

$$\nabla^2 V = -\mathbf{W}$$

پس مقادیر ویژه‌ی \mathbf{W} عبارت است از S و 0 .
 مقادیر ویژه‌ی هسی عبارت است از $-S$ و 0 (با همان فضای ویژه).

the eigenvalues are $-S$ and 0 , with the same eigenspaces.

- فضای ویژه‌ی متناظر با مقدار ویژه‌ی S : فضایی است که توسط بردارهای پروتوتایپ پوشش داده می‌شود.
- فضای ویژه‌ی متناظر با مقدار ویژه‌ی 0 : متمم متعامد فضای تحت پوشش بردارهای پروتوتایپ است.



The high-gain Lyapunov function is a quadratic function. Therefore, the eigenvalues of the Hessian matrix determine its shape. Because the first eigenvalue is negative, V will have negative curvature in X . Because the second eigenvalue is zero, V will have zero curvature in X^\perp .

Because V has negative curvature in X , the trajectories of the Hopfield network will tend to fall into the corners of the hypercube $\{\mathbf{a}: -1 < a_i < 1\}$ that are contained in X .

حافظه‌ی آدرس‌پذیر با محتوا

تحلیل قاعده‌ی هب: رویه‌ی لیاپانوف

LYAPUNOV SURFACE

The high-gain Lyapunov function is a quadratic function. Therefore, the eigenvalues of the Hessian matrix determine its shape. Because the first eigenvalue is negative, V will have negative curvature in X . Because the second eigenvalue is zero, V will have zero curvature in X^\perp .

تابع لیاپانوف با بهره‌ی بالا، یک تابع درجه دوم است. بنابراین، مقادیر ویژه‌ی ماتریس هسی شکل آن را تعیین می‌کند. از آنجا که مقدار ویژه‌ی اول، منفی است $\Leftarrow V$ در X انحنای منفی خواهد داشت. از آنجا که مقدار ویژه‌ی دوم، صفر است $\Leftarrow V$ در X^\perp انحنای صفر خواهد داشت.

Because V has negative curvature in X , the trajectories of the Hopfield network will tend to fall into the corners of the hypercube $\{\mathbf{a}: -1 < a_i < 1\}$ that are contained in X .

از آنجا که V در X انحنای منفی دارد،
خط سیرهای شبکه‌های هاپفیلد تمایل دارند به گوشه‌های ابرمکعب

$$\{\mathbf{a} : -1 < a_i < 1\}$$

که در X واقع است، برسند.

حافظه‌ی آدرس‌پذیر با محتوا

تحلیل قاعده‌ی هب: رویه‌ی لیاپانوف: الگوهای تقلبی

SPURIOUS PATTERNS

در صورتی که ماتریس وزن را با استفاده از قاعده‌ی هب محاسبه کنیم، به‌ازای هر بردار پروتوتایپ، حداقل دو می‌نیمم در تابع لیاپانوف وجود خواهد داشت:

اگر p_q یک بردار پروتوتایپ باشد،
آن‌گاه $-p_q$ نیز در فضای تحت پوشش بردارهای پروتوتایپ (X) خواهد بود.

⇐ قرینه‌ی هر بردار پروتوتایپ در یکی از گوشه‌های ابرمکعب زیر خواهد بود که در X نیز وجود دارد.

$$\{\mathbf{a} : -1 < a_i < 1\}$$

البته تابع لیاپانوف، می‌نیمم‌های دیگری هم دارد که با هیچ یک از الگوهای پروتوتایپ متناظر نیست.

می‌نیمم‌های V در گوشه‌های ابرمکعب خواهند بود که در X هم هستند.
این گوشه‌ها حاوی الگوهای پروتوتایپ نیز خواهند بود.
البته آنها شامل ترکیب خطی الگوهای پروتوتایپ هم هستند.

به می‌نیمم‌های تابع لیاپانوف که جزء الگوهای پروتوتایپ نیستند، **الگوهای تقلبی** گفته می‌شود.

هدف در طراحی شبکه‌ی هاپفیلد:

(۱) حداقل کردن تعداد الگوهای تقلبی و (۲) ایجاد یک ناحیه‌ی جذب برای هر یک از الگوهای پروتوتایپ در صورت امکان

حافظه‌ی آدرس‌پذیر با محتوا

تحلیل قاعده‌ی هب: رویه‌ی لیاپانوف: مثال (۱ از ۲)

EXAMPLE

فرض می‌کنیم ماتریس اتصال (ماتریس وزن) به صورت زیر باشد:

$$\mathbf{W} = \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix}$$

و فرض می‌کنیم این ماتریس وزن با استفاده از قاعده‌ی هب برای الگوی پروتوتایپ زیر طراحی شده باشد:

$$\mathbf{p}_1 = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$$

در این صورت:



$$\mathbf{W} = \mathbf{p}_1(\mathbf{p}_1)^T = \begin{bmatrix} 1 \\ 1 \end{bmatrix} \begin{bmatrix} 1 & 1 \end{bmatrix} = \begin{bmatrix} 1 & 1 \\ 1 & 1 \end{bmatrix}$$

توجه کنید که ماتریس اتصال مورد نظر ما در واقع به صورت زیر است (عناصر قطری صفر):

$$\mathbf{W}' = \mathbf{W} - \mathbf{I} = \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix}$$



$$\mathbf{p}_1 = \begin{bmatrix} 1 \\ 1 \end{bmatrix} \quad \mathbf{W} = \mathbf{p}_1(\mathbf{p}_1)^T = \begin{bmatrix} 1 \\ 1 \end{bmatrix} \begin{bmatrix} 1 & 1 \end{bmatrix} = \begin{bmatrix} 1 & 1 \\ 1 & 1 \end{bmatrix} \quad V(\mathbf{a}) = -\frac{1}{2}\mathbf{a}^T\mathbf{W}\mathbf{a} = -\frac{1}{2}\mathbf{a}^T \begin{bmatrix} 1 & 1 \\ 1 & 1 \end{bmatrix} \mathbf{a}$$



$$\nabla^2 V(\mathbf{a}) = -\mathbf{W} = \begin{bmatrix} -1 & -1 \\ -1 & -1 \end{bmatrix}$$

$$\lambda_1 = -S = -2 \quad \mathbf{z}_1 = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$$

$$X = \{\mathbf{a} : a_1 = a_2\}$$

$$\lambda_2 = 0 \quad \mathbf{z}_2 = \begin{bmatrix} 1 \\ -1 \end{bmatrix}$$

$$X^\perp = \{\mathbf{a} : a_1 = -a_2\}$$

حافظه‌ی آدرس‌پذیر با محتوا


تحلیل قاعده‌ی هب: رویه‌ی لیاپانوف: مثال (۲ از ۲)

EXAMPLE

$$\mathbf{p}_1 = \begin{bmatrix} 1 \\ 1 \end{bmatrix} \quad \mathbf{W} = \mathbf{p}_1(\mathbf{p}_1)^T = \begin{bmatrix} 1 \\ 1 \end{bmatrix} \begin{bmatrix} 1 & 1 \end{bmatrix} = \begin{bmatrix} 1 & 1 \\ 1 & 1 \end{bmatrix} \quad V(\mathbf{a}) = -\frac{1}{2} \mathbf{a}^T \mathbf{W} \mathbf{a} = -\frac{1}{2} \mathbf{a}^T \begin{bmatrix} 1 & 1 \\ 1 & 1 \end{bmatrix} \mathbf{a}$$

تابع لیاپانوف با بهره‌ی بالا

$$\nabla^2 V(\mathbf{a}) = -\mathbf{W} = \begin{bmatrix} -1 & -1 \\ -1 & -1 \end{bmatrix} \quad \text{ماتریس هسی}$$




$$\lambda_1 = -S = -2 \quad \mathbf{z}_1 = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$$

$$X = \{\mathbf{a} : a_1 = a_2\}$$

مقادیر ویژه
بردارهای ویژه
فضاهای ویژه

$$\lambda_2 = 0 \quad \mathbf{z}_2 = \begin{bmatrix} 1 \\ -1 \end{bmatrix}$$

$$X^\perp = \{\mathbf{a} : a_1 = -a_2\}$$



این رویه،
دازای لبه‌های مستقیم در
چپ بالا و راست پایین است.

(این لبه‌ها به دلیل انحنا
صفر در X^\perp هستند)

شبکه با شروع از این نقاط
به یکی از دو نقطه‌ی زیر
همگرا می‌شود:

$$\mathbf{a} = \begin{bmatrix} 1 \\ 1 \end{bmatrix} \quad \text{or} \quad \mathbf{a} = \begin{bmatrix} -1 \\ -1 \end{bmatrix}$$

اگر شبکه کار خود را در سمت راست یا چپ این لبه‌ها آغاز کند،
به یکی از نقاط اولیه‌ی طراحی همگرا می‌شود.
پس همگرایی این سیستم اصلی و سیستمی با اعضای قطری صفر، از هر جنبه یکسان است.



We can zero the diagonal elements of the weight matrix:

$$\mathbf{W}' = \mathbf{W} - Q\mathbf{I}$$

The prototypes remain eigenvectors of this new matrix, but the corresponding eigenvalue is now $(S-Q)$:

$$\mathbf{W}'\mathbf{p}_q = [\mathbf{W} - Q\mathbf{I}]\mathbf{p}_q = S\mathbf{p}_q - Q\mathbf{p}_q = (S-Q)\mathbf{p}_q$$

The elements of X^\perp also remain eigenvectors of this new matrix, with a corresponding eigenvalue of $(-Q)$:

$$\mathbf{W}'\mathbf{a} = [\mathbf{W} - Q\mathbf{I}]\mathbf{a} = \mathbf{0} - Q\mathbf{a} = -Q\mathbf{a}$$

The Lyapunov surface will have negative curvature in X and positive curvature in X^\perp , in contrast with the original Lyapunov function, which had negative curvature in X and zero curvature in X^\perp .

حافظه‌ی آدرس‌پذیر با محتوا

تحلیل قاعده‌ی هب: رویه‌ی لیاپانوف: عناصر قطری صفر

ZERO DIAGONAL ELEMENTS

در بسیاری از مباحث مربوط به شبکه‌های هاپفیلد، اعضای قطری ماتریس وزن برابر با صفر قرار داده می‌شود: می‌خواهیم تأثیر این مسئله را بر روی رویه‌ی لیاپانوف مورد تحلیل قرار دهیم.

در شبکه‌ی حافظه‌ی آدرس‌پذیر با محتوا، همه‌ی اعضای قطری ماتریس وزن برابر با Q (تعداد الگوی پروتوتایپ) است.

پس می‌توانیم عناصر قطری ماتریس وزن را با Q مرتبه کم کردن ماتریس همانی از آن به صفر برسانیم.

پروتوتایپ‌ها، همچنان بردارهای ویژه‌ی این ماتریس جدید باقی می‌مانند، اما مقدار ویژه‌ی متناظر با آنها $(S-Q)$ می‌شود.

عناصر X^\perp نیز بردارهای ویژه‌ی این ماتریس جدید خواهند بود، با مقادیر ویژه‌ی متناظر $-Q$

این رویه‌ی لیاپانوف، دارای انحنا‌ی منفی در X و انحنا‌ی مثبت در X^\perp است.

We can zero the diagonal elements of the weight matrix:

$$W' = W - QI$$

The prototypes remain eigenvectors of this new matrix, but the corresponding eigenvalue is now $(S-Q)$:

$$W'p_q = [W - QI]p_q = Sp_q - Qp_q = (S - Q)p_q$$

The elements of X^\perp also remain eigenvectors of this new matrix, with a corresponding eigenvalue of $(-Q)$:

$$W'a = [W - QI]a = 0 - Qa = -Qa$$

The Lyapunov surface will have negative curvature in X and positive curvature in X^\perp , in contrast with the original Lyapunov function, which had negative curvature in X and zero curvature in X^\perp .



حافظه‌ی آدرس‌پذیر با محتوا

تحلیل قاعده‌ی هب: رویه‌ی لیاپانوف: عناصر قطری صفر: مقایسه (۱ از ۲)

ZERO DIAGONAL ELEMENTS



با مقایسه بین این دو رویه،
تأثیر صفر کردن اعضای قطر اصلی ماتریس وزن
روی تابع لیاپانوف مشخص می‌شود.

از نظر کارایی سیستم می‌توان گفت:
این تأثیر اندکی دارد.



در صورتی که شرایط آغازین شبکه‌ی هاپفیلد
در هر جایی غیر از خط $a_1 = -a_2$ باشد،
آن‌گاه در هر دو مورد،
خروجی شبکه به یکی از گوشه‌های ابرمکعب
 $\{\mathbf{a} : -1 < a_i < 1\}$
همگرا می‌شود که شامل نقاط زیر است.

$$\mathbf{a} = \begin{bmatrix} 1 \\ 1 \end{bmatrix} \quad \text{or} \quad \mathbf{a} = \begin{bmatrix} -1 \\ -1 \end{bmatrix}$$





حافظه‌ی آدرس‌پذیر با محتوا



تحلیل قاعده‌ی هب: رویه‌ی لیاپانوف: عناصر قطری صفر: مقایسه (۲ از ۲)

ZERO DIAGONAL ELEMENTS


در صورتی که شرایط آغازین شبکه‌ی هاپفیلد دقیقاً بر روی خط $a_1 = -a_2$ باشد، و ماتریس وزن W استفاده شود، خروجی شبکه ثابت می‌ماند.



در صورتی که شرایط آغازین شبکه‌ی هاپفیلد دقیقاً بر روی خط $a_1 = -a_2$ باشد، و ماتریس وزن W' استفاده شود، خروجی شبکه به نقطه‌ی زینی در مبدأ همگرا می‌شود.



هیچ‌کدام از این نتایج، مطلوب نیستند (زیرا خروجی شبکه به می‌نیم تابع لیاپانوف همگرا نشده است) اما همگرایی شبکه به نقطه‌ی زینی در کاربردهای عملی مطلوب‌تر است.




If the initial condition falls exactly on the line $a_1 = -a_2$, and the weight matrix \mathbf{W} is used, then the network output will remain constant. If the initial condition falls exactly on the line $a_1 = -a_2$, and the weight matrix \mathbf{W}' is used, then the network output will converge to the saddle point at the origin.

حافظه‌ی آدرس‌پذیر با محتوا

تحلیل قاعده‌ی هب: رویه‌ی لیاپانوف: عناصر قطری صفر: مثال

ZERO DIAGONAL ELEMENTS

$$\mathbf{W}' = \mathbf{W} - Q\mathbf{I} = \begin{bmatrix} 1 & 1 \\ 1 & 1 \end{bmatrix} - \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} = \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix}$$




If the initial condition falls exactly on the line $a_1 = -a_2$, and the weight matrix \mathbf{W} is used, then the network output will remain constant. If the initial condition falls exactly on the line $a_1 = -a_2$, and the weight matrix \mathbf{W}' is used, then the network output will converge to the saddle point at the origin.

شبکه‌ی هاپفیلد

۵

منابع

منبع اصلی



Martin T. Hagan, Howard B. Demuth, Mark H. Beale, Orlando De Jesus,
Neural Network Design,
 2nd Edition, Martin Hagan, 2014.
Chapter 21

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

21 Hopfield Network

Objectives	21-1
Theory and Examples	21-2
Hopfield Model	21-3
Lyapunov Function	21-5
Invariant Sets	21-7
Example	21-8
Hopfield Attractors	21-11
Effect of Gain	21-13
Hopfield Design	21-16
Content-Addressable Memory	21-16
Hebb Rule	21-19
Lyapunov Surface	21-23
Summary of Results	21-25
Solved Problems	21-27
Epilogue	21-37
Further Reading	21-38
Exercises	21-41

Objectives

This chapter will discuss the Hopfield recurrent neural network — a network that was highly influential in bringing about the resurgence of neural network research in the early 1980s. We will begin with a description of the network, and then we will show how Lyapunov stability theory can be used to analyze the network operation. Finally, we will demonstrate how the network can be designed to behave as an associative memory.

This chapter brings together many topics discussed in previous chapters: the discrete-time Hopfield network (Chapter 3), eigenvalues and eigenvectors (Chapter 6), associative memory and the Hebb rule (Chapter 7), Hessian matrices, conditions for optimality, quadratic functions and surface and contour plots (Chapter 8), steepest descent and phase plane trajectories (Chapter 9), continuous-time recurrent networks (Chapter 10), and Lyapunov's Stability Theorem and LaSalle's Invariance Theorem (Chapter 20). This chapter is, in some ways, a culmination of all our previous efforts.