



شبکه‌های عصبی مصنوعی

درس ۷

یادگیری با ناظارت هبی

Supervised Hebbian Learning

کاظم فولادی قلعه

دانشکده مهندسی، پردیس فارابی

دانشگاه تهران




Supervised Hebbian Learning

قاعدۀ هب



Donald O. Hebb (1904-1985)



قاعده‌ی هب: یکی از اولین قوانین یادگیری در شبکه‌های عصبی (دونالد هب، 1949)


هب ابتدا می‌خواست رمان نویس شود و اول در ادبیات انگلیسی مدرک گرفت.
چون به درک خوبی از طبیعت انسان نیاز داشت، فروید را مطالعه کرد
و به روان‌شناسی علاقه‌مند شد.
در روان‌شناسی کارشناسی ارشد گرفت.
در 1936 از دانشگاه هاروارد دکتری گرفت.

کتاب «سازمان رفتار» (1949) :
رفتار می‌تواند توسط **کنش نرون‌ها** توضیح داده شود.

در مقابل با نگاه اسکینر
(مکتب رفتارگرا: همبستگی بین تحریک و پاسخ + رد استفاده از فرضیه‌های فیزیولوژیک)


← مواجهه میان فلسفه‌های «بالا به پایین» و «پایین به بالا»

Hebb's Postulate



“When an axon of cell A is near enough to excite a cell B and repeatedly or persistently takes part in firing it, some growth process or metabolic change takes place in one or both cells such that A’s efficiency, as one of the cells firing B, is increased.”

D. O. Hebb, 1949




اصل موضوع هب

HEBB'S POSTULATE

وقتی یک آکسون از سلول A به اندازه‌ی کافی سلول B را تحریک کند و به طور مکرر یا دائم در فایر کردن آن شرکت کند، یک فرآیند رشد یا تغییر متابولیکی در یک یا هر دو سلول رخ می‌دهد، به طوری‌که اثربخشی A به عنوان یکی از سلول‌های فایر کننده‌ی B افزایش می‌یابد.

دونالد هب، 1949



اصل موضوع هب

توضیح مکانیسم فیزیکی یادگیری در سطح سلولی


HEBB'S POSTULATE

اصل موضوع هب، در واقع توضیح مکانیسم فیزیکی یادگیری در سطح سلولی است.

نظریه‌ی هب، تأثیر اساسی بر پژوهش‌های جاری علوم اعصاب دارد.

پیشینه: اصل شرکت‌پذیری (ویلیام جیمز):

وقتی دو فرآیند مغزی با هم فعال شوند یا در توالی بلافصل فعال شوند، هر یک از این دو فرآیند میل دارد در رخداد مجدد، تحریک خود را بر دیگری منتشر کند.



یادگیری با نظارت هبی

۱

پیوندگر خطی


قانون یادگیری هب

قانون یادگیری هب می‌تواند در ترکیب با انواع معماری‌های شبکه‌ی عصبی استفاده شود.

برای تمرکز بر شناخت قانون یادگیری
از یک معماری بسیار ساده استفاده می‌کنیم:

پیوندگر خطی
(نمونه‌ای از یک نوع شبکه‌ی عصبی به نام: حافظه‌ی انجمنی)

Linear Associator




$$\mathbf{a} = \mathbf{W}\mathbf{p} \quad a_i = \sum_{j=1}^R w_{ij}p_j$$

Training Set:

$$\{\mathbf{p}_1, \mathbf{t}_1\}, \{\mathbf{p}_2, \mathbf{t}_2\}, \dots, \{\mathbf{p}_Q, \mathbf{t}_Q\}$$

پیوندگر خطی

LINEAR ASSOCIATOR


$$\mathbf{a} = \mathbf{W}\mathbf{p} \quad a_i = \sum_{j=1}^R w_{ij}p_j$$

یادگیری Q زوج از بردارهای ورودی / خروجی پروتوتایپ وظیفه:

Training Set:

$$\{\mathbf{p}_1, \mathbf{t}_1\}, \{\mathbf{p}_2, \mathbf{t}_2\}, \dots, \{\mathbf{p}_Q, \mathbf{t}_Q\}$$

پیوندگر خطی

LINEAR ASSOCIATOR

تغییر اندک در ورودی \Leftarrow تغییر اندک در خروجی

$$p = p_q \Rightarrow a = t_q$$

$$p = p_q + \delta \Rightarrow a = t_q + \varepsilon$$

$$\mathbf{a} = \mathbf{Wp} \qquad a_i = \sum_{j=1}^R w_{ij} p_j$$

Training Set:

$$\{\mathbf{p}_1, \mathbf{t}_1\}, \{\mathbf{p}_2, \mathbf{t}_2\}, \dots, \{\mathbf{p}_Q, \mathbf{t}_Q\}$$

یادگیری بانظارت هبی

۳

قاعده هی هب

Hebb Rule



$$w_{ij}^{new} = w_{ij}^{old} + \alpha f_i(a_{iq})g_j(p_{jq})$$

↑ ↑
Postsynaptic Signal Presynaptic Signal

Simplified Form:

$$w_{ij}^{new} = w_{ij}^{old} + \alpha a_{iq} p_{jq}$$

Supervised Form:

$$w_{ij}^{new} = w_{ij}^{old} + t_{iq} p_{jq}$$

Matrix Form:

$$\mathbf{W}^{new} = \mathbf{W}^{old} + \mathbf{t}_q \mathbf{p}_q^T$$

قاعدۀ هب

HEBB RULE

قاعدۀ هب:

اگر دو نرون در دو طرف یک سیناپس همزمان فعال شوند، قوت سیناپس افزایش می‌یابد



اگر یک p_j مثبت یک a_i مثبت تولید کند، وزن رابطه‌ی آنها (w_{ij}) باید افزایش یابد.

$$w_{ij}^{new} = w_{ij}^{old} + \alpha f_i(a_{iq})g_j(p_{jq})$$



Postsynaptic Signal


Presynaptic Signal

\mathbf{p}_q	-امین عنصر بردار j	p_{jq}
\mathbf{a}_q	-امین عنصر بردار i	a_{iq}
	نرخ یادگیری (مثبت)	α

قاعده‌ی هب

HEBB RULE

$$w_{ij}^{new} = w_{ij}^{old} + \alpha f_i(a_{iq})g_j(p_{jq})$$



Simplified Form:

فرم ساده‌شده (قاعده‌ی بدون نظارت)
* به target نیازی ندارد.

$$w_{ij}^{new} = w_{ij}^{old} + \alpha a_{iq} p_{jq}$$

تابع f_i و g_j را خطی در نظر می‌گیریم:

- افزایش وزن: وقتی هم علامت باشند.
- کاهش وزن: وقتی ناهم علامت باشند.

Supervised Form:

فرم با ناظر
* برای سادگی: $\alpha = 1$

$$w_{ij}^{new} = w_{ij}^{old} + t_{iq} p_{jq}$$

قرار دادن t به جای a :
* شبکه چه کاری باید انجام دهد
(به جای شبکه چه کاری انجام می‌دهد)

Matrix Form:

فرم با ناظر (شكل ماتریسی)
* برای سادگی: $\alpha = 1$

$$\mathbf{W}^{new} = \mathbf{W}^{old} + \mathbf{t}_q \mathbf{p}_q^T$$

Batch Operation



$$\mathbf{W} = \mathbf{t}_1 \mathbf{p}_1^T + \mathbf{t}_2 \mathbf{p}_2^T + \dots + \mathbf{t}_Q \mathbf{p}_Q^T = \sum_{q=1}^Q \mathbf{t}_q \mathbf{p}_q^T \quad (\text{Zero Initial Weights})$$

Matrix Form:

$$\mathbf{W} = [\mathbf{t}_1 \ \mathbf{t}_2 \ \dots \ \mathbf{t}_Q] \begin{bmatrix} \mathbf{p}_1^T \\ \mathbf{p}_2^T \\ \vdots \\ \mathbf{p}_Q^T \end{bmatrix} = \mathbf{T} \mathbf{P}^T$$
$$\mathbf{P} = [\mathbf{p}_1 \ \mathbf{p}_2 \ \dots \ \mathbf{p}_Q]$$
$$\mathbf{T} = [\mathbf{t}_1 \ \mathbf{t}_2 \ \dots \ \mathbf{t}_Q]$$

عملیات دسته‌ای

BATCH OPERATION

در ابتدا ماتریس وزن صفر قرار داده می‌شود.

$$\mathbf{W} = \mathbf{t}_1 \mathbf{p}_1^T + \mathbf{t}_2 \mathbf{p}_2^T + \cdots + \mathbf{t}_Q \mathbf{p}_Q^T = \sum_{q=1}^Q \mathbf{t}_q \mathbf{p}_q^T \quad (\text{Zero Initial Weights})$$

هر زوج (\mathbf{p}, \mathbf{t}) یک بار به شبکه نشان داده می‌شود.

Matrix Form:

$$\mathbf{W} = \begin{bmatrix} \mathbf{t}_1 & \mathbf{t}_2 & \dots & \mathbf{t}_Q \end{bmatrix} \begin{bmatrix} \mathbf{p}_1^T \\ \mathbf{p}_2^T \\ \vdots \\ \mathbf{p}_Q^T \end{bmatrix} = \mathbf{T} \mathbf{P}^T$$

$$\mathbf{P} = \begin{bmatrix} \mathbf{p}_1 & \mathbf{p}_2 & \dots & \mathbf{p}_Q \end{bmatrix}$$

$$\mathbf{T} = \begin{bmatrix} \mathbf{t}_1 & \mathbf{t}_2 & \dots & \mathbf{t}_Q \end{bmatrix}$$

Performance Analysis



$$\mathbf{a} = \mathbf{W}\mathbf{p}_k = \left(\sum_{q=1}^Q \mathbf{t}_q \mathbf{p}_q^T \right) \mathbf{p}_k = \sum_{q=1}^Q \mathbf{t}_q (\mathbf{p}_q^T \mathbf{p}_k)$$

Case I, input patterns are orthogonal.

$$(\mathbf{p}_q^T \mathbf{p}_k) = \begin{cases} 1 & q = k \\ 0 & q \neq k \end{cases}$$

Therefore the network output equals the target:

$$\mathbf{a} = \mathbf{W}\mathbf{p}_k = \mathbf{t}_k$$

Case II, input patterns are normalized, but not orthogonal.

$$\mathbf{a} = \mathbf{W}\mathbf{p}_k = \mathbf{t}_k + \boxed{\sum_{q \neq k} \mathbf{t}_q (\mathbf{p}_q^T \mathbf{p}_k)}$$

Error

تحلیل کارآیی

PERFORMANCE ANALYSIS

$$\mathbf{a} = \mathbf{W}\mathbf{p}_k = \left(\sum_{q=1}^Q \mathbf{t}_q \mathbf{p}_q^T \right) \mathbf{p}_k = \sum_{q=1}^Q \mathbf{t}_q (\mathbf{p}_q^T \mathbf{p}_k)$$

حالت یک) الگوهای ورودی متعامد هستند

Case I, input patterns are orthogonal.

$$\begin{aligned} (\mathbf{p}_q^T \mathbf{p}_k) &= 1 & q &= k \\ &= 0 & q &\neq k \end{aligned}$$

Therefore the network output equals the target:

$$\mathbf{a} = \mathbf{W}\mathbf{p}_k = \mathbf{t}_k \quad \text{خروجی درست برای حالت متعامد:}$$

حالت دو) الگوهای ورودی نرمال شده، اما غیر متعامد هستند

Case II, input patterns are normalized, but not orthogonal.

$$\mathbf{a} = \mathbf{W}\mathbf{p}_k = \mathbf{t}_k + \sum_{q \neq k} \mathbf{t}_q (\mathbf{p}_q^T \mathbf{p}_k)$$

Error

میزان خطا وابسته به میزان همبستگی بین الگوهای ورودی پروتوتایپ است.

Example



Banana

Apple

Normalized Prototype Patterns

$$\mathbf{p}_1 = \begin{bmatrix} -1 \\ 1 \\ -1 \end{bmatrix} \quad \mathbf{p}_2 = \begin{bmatrix} 1 \\ 1 \\ -1 \end{bmatrix} \quad \left\{ \mathbf{p}_1 = \begin{bmatrix} -0.5774 \\ 0.5774 \\ -0.5774 \end{bmatrix}, \mathbf{t}_1 = \begin{bmatrix} -1 \end{bmatrix} \right\} \quad \left\{ \mathbf{p}_2 = \begin{bmatrix} 0.5774 \\ 0.5774 \\ -0.5774 \end{bmatrix}, \mathbf{t}_2 = \begin{bmatrix} 1 \end{bmatrix} \right\}$$

Weight Matrix (Hebb Rule):

$$\mathbf{W} = \mathbf{T}\mathbf{P}^T = \begin{bmatrix} -1 & 1 \end{bmatrix} \begin{bmatrix} -0.5774 & 0.5774 & -0.5774 \\ 0.5774 & 0.5774 & -0.5774 \end{bmatrix} = \begin{bmatrix} 1.1548 & 0 & 0 \end{bmatrix}$$

Tests:

Banana $\mathbf{W}\mathbf{p}_1 = \begin{bmatrix} 1.1548 & 0 & 0 \end{bmatrix} \begin{bmatrix} -0.5774 \\ 0.5774 \\ -0.5774 \end{bmatrix} = \begin{bmatrix} -0.6668 \end{bmatrix}$

Apple $\mathbf{W}\mathbf{p}_2 = \begin{bmatrix} 0 & 1.1548 & 0 \end{bmatrix} \begin{bmatrix} 0.5774 \\ 0.5774 \\ -0.5774 \end{bmatrix} = \begin{bmatrix} 0.6668 \end{bmatrix}$

تحلیل کارآیی

مثال

PERFORMANCE ANALYSIS

Banana	Apple	Normalized Prototype Patterns
$\mathbf{p}_1 = \begin{bmatrix} -1 \\ 1 \\ -1 \end{bmatrix}$	$\mathbf{p}_2 = \begin{bmatrix} 1 \\ 1 \\ -1 \end{bmatrix}$	$\left\{ \mathbf{p}_1 = \begin{bmatrix} -0.5774 \\ 0.5774 \\ -0.5774 \end{bmatrix}, \mathbf{t}_1 = \begin{bmatrix} 1 \\ -1 \end{bmatrix} \right\}$ $\left\{ \mathbf{p}_2 = \begin{bmatrix} 0.5774 \\ 0.5774 \\ -0.5774 \end{bmatrix}, \mathbf{t}_2 = \begin{bmatrix} 1 \\ 1 \end{bmatrix} \right\}$

Weight Matrix (Hebb Rule):

$$\mathbf{W} = \mathbf{T}\mathbf{P}^T = \begin{bmatrix} -1 & 1 \end{bmatrix} \begin{bmatrix} -0.5774 & 0.5774 & -0.5774 \\ 0.5774 & 0.5774 & -0.5774 \end{bmatrix} = \begin{bmatrix} 1.1548 & 0 & 0 \end{bmatrix}$$

Tests:

Banana $\mathbf{W}\mathbf{p}_1 = \begin{bmatrix} 1.1548 & 0 & 0 \end{bmatrix} \begin{bmatrix} -0.5774 \\ 0.5774 \\ -0.5774 \end{bmatrix} = \begin{bmatrix} -0.6668 \end{bmatrix}$

خروجی نزدیک به تارگت است، اما خطأ دارد.

Apple $\mathbf{W}\mathbf{p}_2 = \begin{bmatrix} 0 & 1.1548 & 0 \end{bmatrix} \begin{bmatrix} 0.5774 \\ 0.5774 \\ -0.5774 \end{bmatrix} = \begin{bmatrix} 0.6668 \end{bmatrix}$

روال‌هایی برای کاهش خطأ وقتی که الگوهای پروتوتاپ متعامد نباشند وجود دارد (مانند قاعده‌ی شبه وارون)

یادگیری بانظارت هبی

۳۰

قاعده‌ی شبه وارون

Pseudoinverse Rule - (1)



Performance Index: $\mathbf{Wp}_q = \mathbf{t}_q \quad q = 1, 2, \dots, Q$

$$F(\mathbf{W}) = \sum_{q=1}^Q \|\mathbf{t}_q - \mathbf{Wp}_q\|^2$$

Matrix Form: $\mathbf{WP} = \mathbf{T}$

$$\mathbf{T} = [\mathbf{t}_1 \ \mathbf{t}_2 \ \dots \ \mathbf{t}_Q] \quad \mathbf{P} = [\mathbf{p}_1 \ \mathbf{p}_2 \ \dots \ \mathbf{p}_Q]$$

$$F(\mathbf{W}) = \|\mathbf{T} - \mathbf{WP}\|^2 = \|\mathbf{E}\|^2$$

$$\|\mathbf{E}\|^2 = \sum_i \sum_j e_{ij}^2$$

قاعده‌ی شبیه وارون

(۱ از ۲)

PSEUDOINVERSE RULE

Performance Index: $\mathbf{Wp}_q = \mathbf{t}_q \quad q = 1, 2, \dots, Q$ وظیفه‌ی شبکه:

ورودی‌های متعامد با قاعده‌ی هب

$$\mathbf{F}(\mathbf{W}) = 0 \Leftarrow$$

در حالت کلی:

هدف مینیمم کردن $\mathbf{F}(\mathbf{W})$ است

$$\mathbf{W} = \arg \min_{\mathbf{W}} \mathbf{F}(\mathbf{W})$$

Matrix Form:

$$\mathbf{WP} = \mathbf{T}$$

$$\mathbf{T} = \begin{bmatrix} \mathbf{t}_1 & \mathbf{t}_2 & \dots & \mathbf{t}_Q \end{bmatrix} \quad \mathbf{P} = \begin{bmatrix} \mathbf{p}_1 & \mathbf{p}_2 & \dots & \mathbf{p}_Q \end{bmatrix}$$

$$\mathbf{F}(\mathbf{W}) = \|\mathbf{T} - \mathbf{WP}\|^2 = \|\mathbf{E}\|^2$$

$$\|\mathbf{E}\|^2 = \sum_i \sum_j e_{ij}^2 \quad \text{نم ماتریسی: مجموع مربع همه‌ی درایه‌ها}$$

Pseudoinverse Rule - (2)



$$\mathbf{WP} = \mathbf{T}$$

Minimize:

$$F(\mathbf{W}) = \|\mathbf{T} - \mathbf{WP}\|^2 = \|\mathbf{E}\|^2$$

If an inverse exists for \mathbf{P} , $F(\mathbf{W})$ can be made zero:

$$\mathbf{W} = \mathbf{TP}^{-1}$$

When an inverse does not exist $F(\mathbf{W})$ can be minimized using the pseudoinverse:

$$\mathbf{W} = \mathbf{TP}^+$$

$$\mathbf{P}^+ = (\mathbf{P}^T \mathbf{P})^{-1} \mathbf{P}^T$$

قاعده‌ی شبیه وارون

(۱ از ۲)

PSEUDOINVERSE RULE

$$\mathbf{WP} = \mathbf{T}$$

Minimize:

$$F(\mathbf{W}) = \|\mathbf{T} - \mathbf{WP}\|^2 = \|\mathbf{E}\|^2$$

If an inverse exists for \mathbf{P} , $F(\mathbf{W})$ can be made zero:

$$\mathbf{W} = \mathbf{TP}^{-1}$$

در صورت وجود وارون \mathbf{P}
 (عموماً \mathbf{P} مربعی نیست و وارون دقیق ندارد!)

When an inverse does not exist $F(\mathbf{W})$ can be minimized using the pseudoinverse:

$$\mathbf{W} = \mathbf{TP}^+$$

$$\mathbf{P}^+ = (\mathbf{P}^T \mathbf{P})^{-1} \mathbf{P}^T$$

به شرط مستقل خطی بودن ستون‌های \mathbf{P}

Relationship to the Hebb Rule



Hebb Rule

$$\mathbf{W} = \mathbf{T}\mathbf{P}^T$$

Pseudoinverse Rule

$$\mathbf{W} = \mathbf{T}\mathbf{P}^+$$

$$\mathbf{P}^+ = (\mathbf{P}^T \mathbf{P})^{-1} \mathbf{P}^T$$

If the prototype patterns are orthonormal:

$$\mathbf{P}^T \mathbf{P} = \mathbf{I}$$

$$\mathbf{P}^+ = (\mathbf{P}^T \mathbf{P})^{-1} \mathbf{P}^T = \mathbf{P}^T$$

قاعده‌ی شبه وارون

ارتباط با قاعده‌ی هب

RELATIONSHIP TO THE HEBB RULE

Hebb Rule

$$\mathbf{W} = \mathbf{T}\mathbf{P}^T$$

Pseudoinverse Rule

$$\mathbf{W} = \mathbf{T}\mathbf{P}^+$$

$$\mathbf{P}^+ = (\mathbf{P}^T \mathbf{P})^{-1} \mathbf{P}^T$$

If the prototype patterns are orthonormal:

$$\mathbf{P}^T \mathbf{P} = \mathbf{I}$$

اگر الگوهای پروتوتایپ متعامد یکه باشند:

$$\mathbf{P}^+ = (\mathbf{P}^T \mathbf{P})^{-1} \mathbf{P}^T = \mathbf{P}^T$$

Example



$$\left\{ \mathbf{p}_1 = \begin{bmatrix} -1 \\ 1 \\ -1 \end{bmatrix}, \mathbf{t}_1 = \begin{bmatrix} -1 \\ -1 \end{bmatrix} \right\} \quad \left\{ \mathbf{p}_2 = \begin{bmatrix} 1 \\ 1 \\ -1 \end{bmatrix}, \mathbf{t}_2 = \begin{bmatrix} 1 \\ 1 \end{bmatrix} \right\} \quad \mathbf{W} = \mathbf{T}\mathbf{P}^+ = \begin{bmatrix} -1 & 1 \\ -1 & 1 \\ 1 & 1 \end{bmatrix} \begin{pmatrix} \begin{bmatrix} -1 & 1 \\ 1 & 1 \\ -1 & -1 \end{bmatrix} \end{pmatrix}^+$$

$$\mathbf{P}^+ = (\mathbf{P}^T \mathbf{P})^{-1} \mathbf{P}^T = \begin{bmatrix} 3 & 1 \\ 1 & 3 \end{bmatrix}^{-1} \begin{bmatrix} -1 & 1 & -1 \\ 1 & 1 & -1 \end{bmatrix} = \begin{bmatrix} -0.5 & 0.25 & -0.25 \\ 0.5 & 0.25 & -0.25 \end{bmatrix}$$

$$\mathbf{W} = \mathbf{T}\mathbf{P}^+ = \begin{bmatrix} -1 & 1 \end{bmatrix} \begin{bmatrix} -0.5 & 0.25 & -0.25 \\ 0.5 & 0.25 & -0.25 \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 \end{bmatrix}$$

$$\mathbf{W}\mathbf{p}_1 = \begin{bmatrix} 1 & 0 & 0 \end{bmatrix} \begin{bmatrix} -1 \\ 1 \\ -1 \end{bmatrix} = \begin{bmatrix} -1 \\ -1 \end{bmatrix}$$

$$\mathbf{W}\mathbf{p}_2 = \begin{bmatrix} 1 & 0 & 0 \end{bmatrix} \begin{bmatrix} 1 \\ 1 \\ -1 \end{bmatrix} = \begin{bmatrix} 1 \end{bmatrix}$$

قاعدۀ شبه وارون

ارتباط با قاعدۀ هب: مثال

RELATIONSHIP TO THE HEBB RULE

$$\left\{ \mathbf{p}_1 = \begin{bmatrix} -1 \\ 1 \\ -1 \end{bmatrix}, \mathbf{t}_1 = \begin{bmatrix} -1 \\ -1 \end{bmatrix} \right\} \quad \left\{ \mathbf{p}_2 = \begin{bmatrix} 1 \\ 1 \\ -1 \end{bmatrix}, \mathbf{t}_2 = \begin{bmatrix} 1 \\ 1 \end{bmatrix} \right\} \quad \mathbf{W} = \mathbf{T}\mathbf{P}^+ = \begin{bmatrix} -1 & 1 \\ 1 & 1 \\ -1 & -1 \end{bmatrix} \begin{pmatrix} -1 & 1 \\ 1 & 1 \\ -1 & -1 \end{pmatrix}^+$$

$$\mathbf{P}^+ = (\mathbf{P}^T \mathbf{P})^{-1} \mathbf{P}^T = \begin{bmatrix} 3 & 1 \\ 1 & 3 \end{bmatrix}^{-1} \begin{bmatrix} -1 & 1 & -1 \\ 1 & 1 & -1 \end{bmatrix} = \begin{bmatrix} -0.5 & 0.25 & -0.25 \\ 0.5 & 0.25 & -0.25 \end{bmatrix}$$

$$\mathbf{W} = \mathbf{T}\mathbf{P}^+ = \begin{bmatrix} -1 & 1 \end{bmatrix} \begin{bmatrix} -0.5 & 0.25 & -0.25 \\ 0.5 & 0.25 & -0.25 \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 \end{bmatrix}$$

$$\mathbf{Wp}_1 = \begin{bmatrix} 1 & 0 & 0 \end{bmatrix} \begin{bmatrix} -1 \\ 1 \\ -1 \end{bmatrix} = \begin{bmatrix} -1 \\ -1 \end{bmatrix} \qquad \mathbf{Wp}_2 = \begin{bmatrix} 1 & 0 & 0 \end{bmatrix} \begin{bmatrix} 1 \\ 1 \\ -1 \end{bmatrix} = \begin{bmatrix} 1 \end{bmatrix}$$

شبۀ وارون، خروجی دقیق ارائه کرده است.

یادگیری بانظارت هبی

۴

کاربرد

حافظه‌ی خود-پیوندی

(حافظه‌ی خود-انجمانی)

AUTOASSOCIATIVE MEMORY

در حافظه‌ی خود-پیوندی، خروجی مطلوب همان ورودی است:

$$\mathbf{t}_q = \mathbf{p}_q$$


- شبکه، برای ذخیره‌سازی الگوها استفاده می‌شود.
- سپس این الگوها را به خاطر می‌آورد
- حتی وقتی که الگوی خراب به عنوان ورودی به شبکه داده می‌شود.

Autoassociative Memory



$\mathbf{p}_1, \mathbf{t}_1$ $\mathbf{p}_2, \mathbf{t}_2$ $\mathbf{p}_3, \mathbf{t}_3$

$$\mathbf{p}_1 = [-1 \ 1 \ 1 \ 1 \ 1 \ -1 \ 1 \ -1 \ -1 \ -1 \ -1 \ 1 \ 1 \ 1 \ -1 \ \dots \ 1 \ -1]^T$$




$$\mathbf{W} = \mathbf{p}_1\mathbf{p}_1^T + \mathbf{p}_2\mathbf{p}_2^T + \mathbf{p}_3\mathbf{p}_3^T$$

حافظه‌ی خود-پیوندی

(حافظه‌ی خود-انجمنی): مثال


AUTOASSOCIATIVE MEMORY

گرید 6×5
سفید (-1)، سیاه (1)
بسط ستون به ستون ↓



الگوهایی که می‌خواهیم آنها را ذخیره کنیم:

$$\mathbf{p}_1 = [-1 \ 1 \ 1 \ 1 \ 1 \ -1 \ 1 \ -1 \ -1 \ -1 \ -1 \ 1 \ 1 \ -1 \ \dots \ 1 \ -1]^T$$




$$\mathbf{t}_q = \mathbf{p}_q$$

↓



$$\mathbf{W} = \mathbf{p}_1 \mathbf{p}_1^T + \mathbf{p}_2 \mathbf{p}_2^T + \mathbf{p}_3 \mathbf{p}_3^T$$

محاسبه‌ی وزن‌ها با قاعده‌ی هب



چون تنها دو مقدار مجاز داریم.





50% Occluded



67% Occluded



Noisy Patterns (7 pixels)



حافظه‌ی خود-پیوندی




(حافظه‌ی خود-انجمنی): مثال (تست)

AUTOASSOCIATIVE MEMORY

به شبکه، ورودی‌های خراب نشان می‌دهیم:



۵ درصد پوشیدگی (1/2).

50% Occluded





۶۷ درصد پوشیدگی (2/3).


67% Occluded



الگوی نویزی (۷ پیکسل)

Noisy Patterns (7 pixels)





>> nnd7sh

یادگیری با نظارت هبی

۵

شکل های
گوناگون
یادگیری
هبی

Variations of Hebbian Learning



Basic Rule: $\mathbf{W}^{new} = \mathbf{W}^{old} + \mathbf{t}_q \mathbf{p}_q^T$

Learning Rate: $\mathbf{W}^{new} = \mathbf{W}^{old} + \alpha \mathbf{t}_q \mathbf{p}_q^T$

Smoothing: $\mathbf{W}^{new} = \mathbf{W}^{old} + \alpha \mathbf{t}_q \mathbf{p}_q^T - \gamma \mathbf{W}^{old} = (1 - \gamma) \mathbf{W}^{old} + \alpha \mathbf{t}_q \mathbf{p}_q^T$

Delta Rule: $\mathbf{W}^{new} = \mathbf{W}^{old} + \alpha (\mathbf{t}_q - \mathbf{a}_q) \mathbf{p}_q^T$

Unsupervised: $\mathbf{W}^{new} = \mathbf{W}^{old} + \alpha \mathbf{a}_q \mathbf{p}_q^T$

انواع یادگیری هبی

VARIATIONS OF HEBBIAN LEARNING

Basic Rule:

$$\mathbf{W}^{new} = \mathbf{W}^{old} + \mathbf{t}_q \mathbf{p}_q^T$$

Learning Rate:

$$\mathbf{W}^{new} = \mathbf{W}^{old} + \alpha \mathbf{t}_q \mathbf{p}_q^T$$

Smoothing:

$$\mathbf{W}^{new} = \mathbf{W}^{old} + \alpha \mathbf{t}_q \mathbf{p}_q^T - \gamma \mathbf{W}^{old} = (1 - \gamma) \mathbf{W}^{old} + \alpha \mathbf{t}_q \mathbf{p}_q^T$$

Delta Rule:

$$\mathbf{W}^{new} = \mathbf{W}^{old} + \alpha (\mathbf{t}_q - \mathbf{a}_q) \mathbf{p}_q^T$$

Unsupervised:

$$\mathbf{W}^{new} = \mathbf{W}^{old} + \alpha \mathbf{a}_q \mathbf{p}_q^T$$



انواع یادگیری هبی

قاعده‌ی پایه

VARIATIONS OF HEBBIAN LEARNING

Basic Rule:

$$\mathbf{W}^{new} = \mathbf{W}^{old} + \mathbf{t}_q \mathbf{p}_q^T$$

مشکل: ماتریس وزن می‌تواند خیلی بزرگ شود.
(وقتی که تعداد ورودی‌های آموزشی زیاد باشد)

انواع یادگیری هبی

با نرخ یادگیری

VARIATIONS OF HEBBIAN LEARNING

Learning Rate:

$$\mathbf{W}^{new} = \mathbf{W}^{old} + \alpha \mathbf{t}_q \mathbf{p}_q^T$$

نرخ یادگیری α می‌تواند میزان افزایش در وزن را محدود کند

$$\alpha < 1$$

(فصل ۱۶)

انواع یادگیری هبی

با هموارسازی (یادگیری فیلتری)

VARIATIONS OF HEBBIAN LEARNING

Smoothing:

$$\mathbf{W}^{new} = \mathbf{W}^{old} + \alpha \mathbf{t}_q \mathbf{p}_q^T - \gamma \mathbf{W}^{old} = (1 - \gamma) \mathbf{W}^{old} + \alpha \mathbf{t}_q \mathbf{p}_q^T$$

مانند یک فیلتر هموارکننده عمل می‌کند.

γ : نرخ زوال

$\gamma < 0$: ورودی‌های تازه‌تر را واضح‌تر به خاطر می‌آورد

$\gamma \rightarrow 0$: قاعده‌ی یادگیری پایه
 $\gamma \rightarrow 1$: به سرعت ورودی‌های قدیمی را از خاطر می‌برد.

(فصل ۱۴)

انواع یادگیری هبی

قاعده‌ی دلتا

VARIATIONS OF HEBBIAN LEARNING

Delta Rule:

$$\mathbf{W}^{new} = \mathbf{W}^{old} + \alpha(\mathbf{t}_q - \mathbf{a}_q)\mathbf{p}_q^T$$

خطا

قاعده‌ی دلتا:

تنظیم وزن‌ها با هدف مینیمم‌سازی مربعات خطأ

مزیت:

امکان به روز کردن وزن‌ها بعد از ارائه‌ی هر تک ورودی
 (شبه وارون نیاز به همه‌ی ورودی‌ها به صورت یکجا دارد).
 * وفق‌یابی با محیط در حال تغییر

(فصل ۱۰)

انواع یادگیری هبی

بدون ناظارت

VARIATIONS OF HEBBIAN LEARNING

Unsupervised:

$$\mathbf{W}^{new} = \mathbf{W}^{old} + \alpha \mathbf{a}_q \mathbf{p}_q^T$$



به جای تارگت t_q

(اصل موضوع هب، به شکل بدون ناظر اشاره دارد)


(فصل ۱۵)

یادگیری بانظارت هبی

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 7

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

7 Supervised Hebbian Learning

Objectives	7-1
Theory and Examples	7-2
Linear Associator	7-3
The Hebb Rule	7-4
Performance Analysis	7-5
Pseudoinverse Rule	7-7
Application	7-10
Variations of Hebbian Learning	7-12
Summary of Results	7-14
Solved Problems	7-16
Epilogue	7-29
Further Reading	7-30
Exercises	7-31

Objectives

The Hebb rule was one of the first neural network learning laws. It was proposed by Donald Hebb in 1949 as a possible mechanism for synaptic modification in the brain and since then has been used to train artificial neural networks.

In this chapter we will use the linear algebra concepts of the previous two chapters to explain why Hebbian learning works. We will also show how the Hebb rule can be used to train neural networks for pattern recognition.

7.1