

شبکه‌های حافظه انجمنی

دکتر محمد باقر منهاج
دانشکده مهندسی برق
دانشگاه امیرکبیر

زمستان ۱۳۹۱



دانشگاه صنعتی امیرکبیر
(پلی تکنیک تهران)



سر فصل مطالب

- شبکه حافظه انجمنی و قانون یادگیری هب و آنالیز عملکرد آن
- معیار حداقل خطا و مسائل حل شده
- قانون یادگیری بدون ناظر هب، شبکه‌های اینستار و اوتستار
- قانون کوهنن و شبکه هاپفیلد گسسته مفاهیم اولیه و پایه‌ای

اهداف:

- بررسی شبکه‌ها و یادگیری انجمنی و ارائه مجموعه‌ای از قوانین ساده یادگیری از نوع با ناظر و بدون ناظر



دانشگاه صنعتی امیرکبیر
(پلی تکنیک تهران)

شبکه حافظه انجمنی و قانون یادگیری هب و آنالیز عملکرد آن

مقدمه



مقدمه



□ فصل ۱: یکی از عملکردهای اولیه مغز، خاصیت حافظه انجمنی است. عملکرد آن بازیابی مجموعه کاملی از اطلاعات حافظه در شرایطی است که یک قسمت کافی از اطلاعات به سیستم عصبی داده شود. شبکه حافظه انجمنی، یک شبکه عصبی تک لایه است که یک سری بردارها را به بردارهای دیگر ارتباط می دهد. (نسبت دادن اسم یک فرد به چهره اش)

□ فصلهای ۳ و ۴: شبکه پرسپترون یک شبکه انجمنی است.

□ که هدف همگرایی مجانبی شبکه است.

□ شبکه هایپلید گسسته که در ادامه بررسی می شود،

انجمنی است.

شبکه های انجمنی



پیشخور

پسخور



مقدمه



□ شبکه‌های انجمنی و تقسیم‌بندی دیگری بر اساس نوع نگاشت:

شبکه های انجمنی



دیگر انجمن

خود انجمن



□ فصل ۴: یادگیری پرسپترون با ناظر مورد بررسی قرار گرفت.

□ در این فصل مجموعه‌ای از قوانین ساده یادگیری با ناظر و بدون ناظر بحث می‌شود.

□ همچنین خواهیم دید که چگونه میتوان به شبکه های عصبی انجمنی انتسابات را ارائه نموده و شبکه مورد نظر چگونه آنها را می‌آموزد و يك انتساب جدید را هم فرا می‌گیرد بدون آنکه موارد قبلی را از یاد ببرد.



مقدمه

نکته :

- حافظه در فرهنگ نرو- بیولوژی : ایجاد تغییرات نسبی عصبی توسط عمل متقابل یک ارگانیسم با محیط اطرافش.
- حافظه باید در دسترس سیستم عصبی باشد.
- الگویی در حافظه ذخیره میشود باید از طریق پروسه یادگیری باشد.
- حافظه‌های انجمنی : حافظه‌هایی که دارای طبیعت توزیعی می‌باشند و بر اساس اصل پایه‌ای محرك - پاسخ عمل می‌کنند (کارکردهای انجمنی).



دانشگاه صنعتی امیرکبیر
(پلی تکنیک تهران)

شبکه حافظه انجمنی و قانون یادگیری هب و آنالیز عملکرد آن

شبکه انجمنی خطی و قانون
یادگیری هب



شبکه انجمنی خطی و قانون یادگیری هب

□ قانون یادگیری هب یکی از اولین قوانین یادگیری شبکه‌های عصبی و پایه تمامی قوانین پیچیده‌تر شبکه‌های انجمنی می‌باشد. دونالد هب (1949).

□ "زمانی که یک اکسان از سلول A بتواند سلول B را به طور مداوم و متناوب تحریک کند، تغییر متابولیکی یا روند رشدی در یک یا هر دو سلول صورت می‌گیرد. بطوری که کارایی A به عنوان یکی از سلول‌هایی که B را تحریک می‌کند افزایش می‌یابد."

□ ویلیام جیمز، فیلسوف و روان‌شناس معروف انگلیسی ۱۸۹۰:

□ "زمانی که دو پروسه مغزی همزمان و یا یکی پس از دیگری فعال شوند، یکی از آن پروسه‌ها پس از بارها تکرار، تشدید فعالیت خود را به دیگری منتقل خواهد کرد."



شبکه انجمنی خطی و قانون یادگیری هب

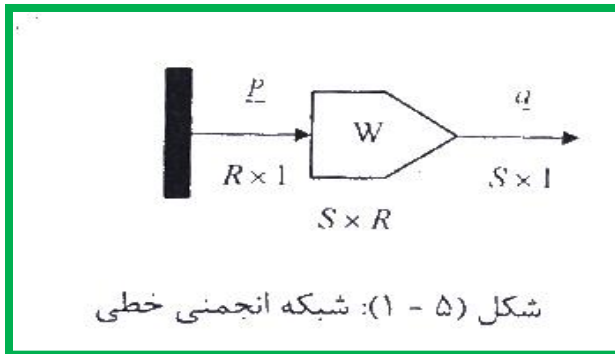
- " اگر يك عنصر پردازشي، يك ورودی را از عنصر پردازشي دیگر دریافت کند و هر دوي آنها همزمان فعال باشند وزنه سیناپسی مابین این دو عنصر پردازشي تقویت می‌شود. "
- اجتماع نرونها ي مرتبط ← توانایی خود سازماندهی
- تعلق سلولها به بیش از يك اجتماع سلولي ← فهم پدیده های روانشناسی
- نکته قابل توجه: ایجاد الگوهای عصبی پایدار و نسبتاً طولانی در سطوح فعال نروني ← فعالیت‌های دماغي و روانی
- همین امر باعث شناخت افزون‌تر فعالیت ذهنی و مغزی با به کارگیری مدل‌های عصبی پسخور گردید. از جمله این مدل‌ها می‌توان به شبکه‌های هایفلید و گراسبرگ اشاره کرد که در جلد دوم کتاب بطور کامل مورد بررسی قرار خواهند گرفت.



شبکه انجمنی خطی و قانون یادگیری هب

□ شبکه حافظه انجمنی خطی

جیمز اندرسون و تئوکوهنن ۱۹۶۸-۱۹۷۲



$$\underline{a} = W \cdot \underline{p}$$

$$a_i = \sum_{j=1}^R w_{ij} p_j$$

هدف اصلی: یادگیری Q زوج ورودی و خروجی $\{(p^i, t^i), i=1, \dots, Q\}$ می باشند

$$\underline{p} = \underline{p}^q \rightarrow \underline{a} = \underline{t}^q$$

$$\underline{p} = \underline{p}^i + \underline{\varepsilon} \rightarrow \underline{a}^i = w(\underline{p}^i + \underline{\varepsilon}) = \underline{t}^i + w \underline{\varepsilon} = \underline{t}^i + \underline{\delta}$$

همچنین



شبکه انجمنی خطی و قانون یادگیری هب

قانون یادگیری هب

« اگر خروجیهای دو نرون توسط یک وزنه به هم متصل هستند هم علامت باشند، وزنه مابین آنها دو تقویت می شود»

- توانایی های فکری و نرونها ی بیولوژیکی
- پردازش یادگیری در سیستم های بیولوژیکی
- سوال : چگونه یاد می گیریم؟
- ساده ترین قاعده شاید همین قانون یادگیری هب باشد
- «یادگیری» یعنی «کد کردن اطلاعات». سیستم الگو را در ساختارش کد کند، می گویند الگویی را یاد گرفته است.



شبکه انجمنی خطی و قانون یادگیری هب

قانون یادگیری هب

- اگر این دو عنصر بطور همزمان فعال نشوند قاعدتا براساس تعبیر فوق، آنگاه بایستی وزن وزنه سیناپسی کاهش یابد.
- بنابراین وقوع يك تغییر در سیناپس به سطح فعالیت نرونهاى دو طرف آن ودر نتیجه به زمان وقوع این فعالیتها بستگی دارد.
- ایجاد يك تغییر محلي در وزنه‌هاي سیناپسی، به تلفیق سطوح فعالیت نرونهاي دو طرف سیناپس (زیرا اتفاقي دوسطح فعالیت نروني در يك فاصله زماني كوچك، جهت ایجاد تغییر در وزنه سیناپسی کفایت خواهد نمود) و یا به همبستگی بین سطوح فعالیت نرونها مشروط می‌شود.
- اگر همبستگی مثبت باشد وزنه سیناپسی افزایش خواهد یافت، همچنین عکس این مطلب نیز صادق است، یعنی همبستگی منفي یا صفر باعث کاهش وزنه سیناپسی خواهد شد.



شبکه انجمنی خطی و قانون یادگیری هب

قانون یادگیری هب

در شبکه انجمنی خطی در دو طرف وزنه سیناپسی w_{ij} سطوح فعالیت a_i و p_j وجود دارند. با توجه به قانون کلی تنظیم پارمترها خواهیم داشت:

□ یادگیری بدون ناظر هب:

$$w_{ij}(K+1) = w_{ij}(k) + \Delta w_{ij}(k) \quad \Delta w_{ij}(k) = \psi(a_i(k), p_j(k); k)$$

$$\Delta w_{ij}(K) = \alpha f_i(a_i) g_j(p_j). \quad \alpha > 0$$

$$\Delta w_{ij}(K) = \alpha a_i p_j$$

نرخ یادگیری

□ یادگیری با ناظر هب:

$$w_{ij}(K+1) = w_{ij}(k) + t_i p_j$$

$$w_i(k+1) = w_i(k) + t_i^q (\underline{p}^q)^T, i = 1, \dots, S \quad W^n = W^0 + \sum_{q=1}^Q t^q (\underline{p}^q)^T \quad W^n - W^0 = TP^T$$



شبکه انجمنی خطی و قانون یادگیری هب

آنالیز عملکرد قانون هب

$$(\underline{p}^i)^T \underline{p}^j = \delta_{ij} \quad \delta_{ij} = \begin{cases} 1, i = j \\ 0, i \neq j \end{cases}$$

خروجی مطلوب

$$\underline{a} = W \underline{p}^L = \left(\sum_{q=1}^Q \underline{t}^q (\underline{p}^q)^T \right) \underline{p}^L = \sum_{q=1}^Q \underline{t}^q (\underline{p}^q)^T \cdot \underline{p}^L = \sum_{q=1}^Q \underline{t}^q \delta_{qL} = \underline{t}^L \leftarrow$$

ورودی شبکه

← اگر يك شبکه انجمنی خطی با قانون یادگیری هب، آموزش دیده باشد و بردارهای ورودی مرجع متعامد و یکه باشند، در صورت اعمال یکی از بردارهای ورودی مرجع به شبکه، خروجی آن برابر با خروجی مطلوب متناظر خواهد بود.



شبکه انجمنی خطی و قانون یادگیری هب

مثال :

□ الگوهای مرجع شبکه: $\underline{p}^1 = \begin{bmatrix} 1 \\ 1 \end{bmatrix}, \underline{p}^2 = \begin{bmatrix} 1 \\ -1 \end{bmatrix}, \underline{p}^3 = \begin{bmatrix} -1 \\ 1 \end{bmatrix}$

□ یک‌سازی:

$$\underline{p}^1 = \begin{bmatrix} \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} \end{bmatrix}, \underline{p}^2 = \begin{bmatrix} \frac{1}{\sqrt{2}} \\ -\frac{1}{\sqrt{2}} \end{bmatrix}, \underline{p}^3 = \begin{bmatrix} -\frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} \end{bmatrix}$$

□ خروجیهای مطلوب بردارهای مرجع: $\underline{t}^1 = \begin{bmatrix} 1 \\ 1 \end{bmatrix}, \underline{t}^2 = \begin{bmatrix} 1 \\ -1 \end{bmatrix}, \underline{t}^3 = \begin{bmatrix} -1 \\ -1 \end{bmatrix}$

□ $W = 0$

□ شبکه خروجیهای متناظر:

$$W = T.P^T = \begin{bmatrix} 1 & 1 & -1 \\ 1 & -1 & -1 \end{bmatrix} \begin{bmatrix} \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} & -\frac{1}{\sqrt{2}} \\ -\frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \end{bmatrix} = \begin{bmatrix} \frac{2}{\sqrt{2}} & -\frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \end{bmatrix}$$

$$\underline{a}^1 = W.\underline{p}^1 = \begin{bmatrix} \frac{1}{\sqrt{2}} & -\frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \end{bmatrix} \begin{bmatrix} \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} \end{bmatrix} = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$$

$$\underline{a}^2 = W.\underline{p}^2 = \begin{bmatrix} \frac{3}{\sqrt{2}} & -\frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \end{bmatrix} \begin{bmatrix} \frac{1}{\sqrt{2}} \\ -\frac{1}{\sqrt{2}} \end{bmatrix} = \begin{bmatrix} 2 \\ 0 \end{bmatrix}$$

$$\underline{a}^3 = W.\underline{p}^3 = \begin{bmatrix} \frac{3}{\sqrt{2}} & -\frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \end{bmatrix} \begin{bmatrix} -\frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} \end{bmatrix} = \begin{bmatrix} -2 \\ 0 \end{bmatrix}$$



شبکه انجمنی خطی و قانون یادگیری هب

ادامه مثال :

□ فرض: که بردارهای ورودی مرجع یکه بوده لکن متعامد نیستند. در این صورت خواهیم داشت:

$$\underline{a}^l = W \underline{P}^l = \sum_{q=1}^Q \underline{t}^q (\underline{p}^q)^T \cdot \underline{P}^l$$

$$\underline{a}^l = \underline{t}^l (\underline{P}^l)^T \cdot \underline{P}^l + \sum_{\substack{q=1 \\ q \neq l}}^Q \underline{t}^q (\underline{p}^q)^T \cdot \underline{P}^l = \underline{t}^l + \sum_{\substack{q=1 \\ q \neq l}}^Q \underline{t}^q (\underline{p}^q)^T \cdot \underline{p}^l$$

$$\underline{e}^l = \underline{a}^l - \underline{t}^l = \sum_{\substack{q=1 \\ q \neq l}}^Q \underline{t}^q (\underline{p}^q)^T \cdot \underline{p}^l$$

□ مقدار خطای خروجی شبکه:

$$\underline{e}^2 = \underline{a}^2 - \underline{t}^2 = \underline{t}^1 \cdot (\underline{p}^1)^T \cdot \underline{p}^2 + \underline{t}^3 (\underline{p}^3)^T \underline{p}^2$$

$$= \begin{bmatrix} 1 \\ 1 \end{bmatrix} \begin{bmatrix} \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \end{bmatrix} \begin{bmatrix} \frac{1}{\sqrt{2}} \\ -\frac{1}{\sqrt{2}} \end{bmatrix} + \begin{bmatrix} -1 \\ -1 \end{bmatrix} \begin{bmatrix} -\frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \end{bmatrix} \begin{bmatrix} \frac{1}{\sqrt{2}} \\ -\frac{1}{\sqrt{2}} \end{bmatrix} = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$$



شبکه انجمنی خطی و قانون یادگیری هب

حداقل کردن خطا

□ قانون شبه معکوس:

$$J(W) = \frac{1}{Q} \sum_{q=1}^Q \|t^q - \underline{a}^q\|^2$$

$$= \frac{1}{Q} \sum_{q=1}^Q \|t^q - W \underline{p}^q\|^2$$

$$J(W) = \frac{1}{Q} \|T - WP\|^2$$

□ فرم ماتریسی:

□ حال بعنوان مثال چند حالت را در نظر میگیریم:

$$P \in R^{-1}$$



$$P^+ = \begin{cases} \frac{1}{p}, p \neq 0 \\ 0, p = 0 \end{cases}$$

$$P \in R^{n \times n}$$



$$\underline{P}^+ = \begin{cases} \frac{\underline{p}^T}{\underline{p}^T \underline{p}}, p \neq 0 \\ 0, \underline{P} = 0 \end{cases}$$

$$P \in R^{n \times m}$$

سطرهای P مستقل خطی باشند $P \neq 0 \rightarrow P^+ = P^T (PP^T)^{-1}$

سطرهای P مستقل خطی باشند $P \neq 0 \rightarrow P^+ = (P^T P)^{-1} P^T$

شبه معکوس P برابر می شود با 0 $p=0 \rightarrow 0$



شبکه انجمنی خطی و قانون یادگیری هب

محاسبه ماتریس شبه معکوس از طریق تجزیه مقادیر تکینه

تعریف: برای ماتریس $A \in R^{n \times m}$ با رتبه $\min(m, n) \geq \text{rank}(A) = p$ ، ماتریسهای متعامد یکه $U \in R^{m \times p}$ و $V \in R^{n \times p}$ موجودند بطوری که:

$$U = [\underline{u}_1, \dots, \underline{u}_p], \quad V = [\underline{v}_1, \dots, \underline{v}_p], \quad \underline{u}_i^T \underline{u}_j = \delta_{ij}, \quad \underline{v}_i^T \underline{v}_j = \delta_{ij}$$

$$V^T A U = \begin{bmatrix} \delta_1 & & \\ & \delta_2 & \\ & & \delta_3 \end{bmatrix} = \text{diag}([\delta_1, \dots, \delta_p]) \quad A^T A \underline{u}_i = \delta_i^2 \underline{u}_i \quad A A^T \underline{v}_i = \delta_i^2 \underline{v}_i$$

$$\delta_i = \begin{cases} [\lambda_i(AA^T)]^{\frac{1}{2}}, & n \leq m \\ [\lambda_i(A^T A)]^{\frac{1}{2}}, & n \geq m \end{cases} \quad \delta_i = [\lambda_i(p^T p)]^{\frac{1}{2}}, \quad i = 1, \dots, p$$



شبکه انجمنی خطی و قانون یادگیری هب

محاسبه ماتریس شبه معکوس از طریق تجزیه مقادیر تکینه

- ماتریس $P^T P$ يك ماتریس متقارن مثبت نیمه معین است. در نتیجه تمامی مقادیر ویژه آن مثبت یا صفرند و مقادیر تکینه نیز همگی مثبت و یا \cdot خواهند بود. δ_i ها را بصورت زیر مرتب می‌کنیم:

$$\delta_1 \geq \delta_2 \geq \dots \geq \delta_{r+1} = \delta_{r+2} = \dots = \delta_p = \cdot$$

$$\text{Rank}(P) = r \quad \square$$

- فضای پوچ ماتریس و فضای برد ماتریس:

$$R(P) = \text{span}\{\underline{u}_1, \dots, \underline{u}_r\}$$

$$N(P) = \text{span}\{\underline{v}_{r+1}, \dots, \underline{v}_n\}$$



شبکه انجمنی خطی و قانون یادگیری هب

مثال : مثال قبلی را در نظر گرفته و ماتریس وزنی W را محاسبه می‌کنیم:

$$W^+ = TP^+ = TP^T (PP^T)^{-1} = \begin{bmatrix} 1 & 0 \\ \frac{1}{2} & \frac{1}{2} \end{bmatrix}$$

□ خروجی شبکه به ازای ورود هر یک از الگوها:

$$\underline{a}^1 = W^* \underline{p}^1 = \begin{bmatrix} 1 & 0 \\ \frac{1}{2} & \frac{1}{2} \end{bmatrix} \begin{bmatrix} 1 \\ 1 \end{bmatrix} = \begin{bmatrix} 1 \\ 1 \end{bmatrix} = \underline{t}^1 \quad \underline{a}^2 = W^* \underline{p}^2 = \begin{bmatrix} 1 & 0 \\ \frac{1}{2} & \frac{1}{2} \end{bmatrix} \begin{bmatrix} 1 \\ -1 \end{bmatrix} = \begin{bmatrix} 1 \\ 0 \end{bmatrix} \neq \underline{t}^2 \quad \underline{a}^3 = W^* \underline{p}^3 = \begin{bmatrix} 1 & 0 \\ \frac{1}{2} & \frac{1}{2} \end{bmatrix} \begin{bmatrix} -1 \\ 1 \end{bmatrix} = \begin{bmatrix} -1 \\ 0 \end{bmatrix} \neq \underline{t}^3$$

□ نتیجه: میزان خطای خروجی شبکه در این روش از یادگیری هب در مثال قبلی کمتر است.



دانشگاه صنعتی امیرکبیر
(پلی تکنیک تهران)

معیار حداقل خطا و مسائل حل شده

مسائل حل شده



مسائل حل شده

□ مسائل حل شده (۱):

□ فرض کنید که شبکه خود انجمنی با استفاده از قانون برای L الگوی متعامد با تعداد عناصر R طراحی شده است. عناصر هر الگو $+1$ - هستند. ماتریس وزنی مناسب را به دست آورده و نشان دهید که L الگو \underline{p}^i ها بردارهای ویژه آن هستند.

□ جواب : با توجه به این که شبکه عصبی در این جا يك شبکه خود انجمنی می باشد خواهیم داشت:

$$W \underline{p}^i = \underline{p}^i, i=1,2,\dots,L \quad W[\underline{p}^1, \dots, \underline{p}^L] = [\underline{p}^1, \dots, \underline{p}^L] \quad W = PP^T = \sum_{q=1}^L \underline{p}^q (\underline{p}^q)^T \quad \underline{a} = W \underline{p}^l = \sum_{q=1}^L \underline{p}^q (\underline{p}^q)^T \cdot \underline{p}^l$$

$$(\underline{p}^q)^T \underline{p}^l = \delta_{ql} = \begin{cases} R & l=q \\ 0, & l \neq q \end{cases}$$

$$\underline{a} = W \underline{p} = \sum_{i=1}^L \alpha_i W \underline{p}^i = \sum_{i=1}^L \alpha_i R \underline{p}^i = R \sum_{i=1}^L \alpha_i \underline{p}^i = R \underline{p}$$

$$\underline{a} = W \underline{v}^j = \sum_{q=1}^L \underline{p}^q (\underline{p}^q)^T \underline{v}^j = \cdot, i = 1, 2, \dots, R-L$$



مسائل حل شده

□ مسائل حل شده (۲):

□ قانون هب را برای نرون α م از لایه اول و نرون α م از لایه دوم يك شبکه پیشخور تعمیم دهید.

$$\Delta w_{ji}(k) = \alpha a_i^1(k) a_j^2(k)$$

□ جواب :

$$w_{ji}(k+1) = w_{ji}(k) + \alpha a_i^1(k) a_j^2(k)$$



مسائل حل شده

□ مسائل حل شده (۳):

□ قانون هب را برای مساله قبل در حالت آماری بنویسید.

□ جواب : روش دیگر نمایش قانون هب به این شکل است که تغییرات در وزنه سیناپسی متناسب با همستگی مابین فعالیتهای نرونهاي دوسر وزنه سیناپسی در نظر گرفته می شود در این صورت:

$$\Delta w_{ji}(k) = \alpha E \left[\left(a_j^2(k) - E(a_j^2(k)) \right) \left(a_i^1(k) - E(a_i^1(k)) \right) \right]$$



مسائل حل شده

□ مسائل حل شده (۴):

□ متدهای دیگر یادگیری از نوع هب را بررسی کنید.

□ جواب : یکی از مشکلات در قانون یادگیری اولیه هب، این است که در صورت زیاد بودن تعداد الگوها در مجموعه داده‌های یادگیری ماتریس وزنی دارای عناصر بسیار بزرگی خواهد شد. به قانون یادگیری اولیه هب توجه کنید:

$$W(k+1) = W(k) + \underline{a}^2(k) (\underline{a}^1(k))^T \quad W(k+1) = W(k) + \alpha \underline{a}^2(k) (\underline{a}^1(k))^T - \beta W(k) \quad \cdot < \beta, \alpha < 1$$

$$= (1 - \beta)W(k) + \alpha \underline{a}^2(k) (\underline{a}^1(k))^T \quad W(k+1) = (1 - \beta)W(k) + \alpha t(k) \underline{p}^T(k) \quad W(k+1) = W(k) + \alpha (\underline{t}^q(k) - W(k) \underline{p}^q) (\underline{p}^q)^T$$

□ مزیت این روش، وزن‌ها پس از ارائه هر الگوی جدید تنظیم شده و این ترتیب برای تنظیم پارامترها، موجب می‌شود تا قانون یادگیری خود را با تغییرات محیط وفق دهد.



مسائل حل شده

□ مسائل حل شده (۵):

- در تمامی مثال‌های شناسایی الگو از بردارهایی استفاده شد که عناصر آن‌ها متعلق به مجموعه $\{-1, 1\}$ بودند چه تغییری در ساختار شبکه انجمنی باید صورت گیرد تا عناصر بردار متعلق به مجموعه باشند
- جواب : فرض کنید که زوج بردارهای ورودی - خروجی به مجموعه $\{-1, 1\}$ متعلق باشند:

$$\{(\underline{p}^i, \underline{t}^i), i = 1, \dots, Q\}, \quad \underline{p}^i \in \{-1, 1\}^{R \times l}, \quad \underline{t}^i \in \{-1, 1\}^{S \times 1}$$

$$\underline{q} = \frac{1}{2} \underline{p} + \frac{1}{2} \underline{1}$$


$$\underline{1} = \begin{bmatrix} 1 \\ \cdot \\ \cdot \\ \cdot \\ \cdot \\ 1 \end{bmatrix}_{R \times l}, \quad \underline{p} \in \{-1, 1\}^{R \times l}$$




مسائل حل شده

□ مسائل حل شده (ادامه ۵):

- دو ساختار را برای شناسایی الگوهای دیجیتالی که عناصر آن متعلق به
- مجموعه $\{-1, 1\}$ و یا $\{-1, 1\}$ هستند در نظر می‌گیریم.
- ارتباط بین پارامترهای دو ساختار:



الف - الگوهای دوقطبی $\{-1, 1\}$



ب - الگوهای باینری $\{0, 1\}$

شکل (۵-۲): دو ساختار برای الگوهای دیجیتالی

$$\underline{n}_b = \underline{b} + W_b \underline{q}$$

$$= \underline{b} + W_b \left(\frac{1}{2} \underline{p} + \frac{1}{2} \underline{1} \right) = \underline{b} + \frac{1}{2} W_b \underline{p} + \frac{1}{2} W_b \underline{1}$$

$$= \underline{n} = W \underline{p} \quad W_b = 2W$$

$$\underline{b} = -\frac{1}{2} W_b \underline{1} = W \underline{1}$$



مسائل حل شده

□ مسائل حل شده (۶):

□ - در شبکه‌های خودانجمی خطی، اگر عناصر قطری ماتریس وزنی W همگی ۰ باشند پاسخ شبکه چگونه تغییر خواهد نمود؟

□ جواب : در شبکه‌های خود انجمی ماتریس T برابر با ماتریس P است و طبق قانون هب ماتریس وزنی W برابر با PP^T می‌باشد. برای صفر نمودن عناصر قطری اگر فرض کنیم که L الگو برای ذخیره سازی و بازیابی به عنوان بردارهای مرجع داشته باشیم تبدیل زیر را انجام می‌دهیم:

$$W' = PP^T - LI, P = [\underline{p}^1, \dots, \underline{p}^L] \quad W' \underline{p}^q = PP^T \underline{p}^q - L \underline{p}^q = [\underline{p}^1, \dots, \underline{p}^L] \begin{bmatrix} (\underline{p}^1)^T \underline{p}^q \\ \vdots \\ (\underline{p}^L)^T \underline{p}^q \end{bmatrix} - L \underline{p}^q = L \underline{p}^q - L \underline{p}^q = O \cdot \underline{p}^q$$

□ هر بردار \underline{p}^q يك بردار ویژه ماتریس W با مقدار ویژه ۰ است. از این رو شبکه‌های خود انجمی برای ماتریس وزنی W که عناصر قطری آن صفرند، همچنان عمل خواهند نمود.



دانشگاه صنعتی امیرکبیر
(پلی تکنیک تهران)

قانون یادگیری بدون ناظر هب، شبکه‌های اینستار و اوتستار

قانون یادگیری بدون ناظر هب



قانون یادگیری بدون ناظر هب

□ مقدمه

□ شکل بدون ناظر یادگیری هب.

□ چگونه می‌توان ارتباطها را توسط شبکه‌ها نمایش داد و چطور شبکه می‌تواند یک ارتباط جدید را فرا گیرد.

□ یک نرون را با تابع غیرخطی اشباع در نظر بگیرید. ورودی نرون، یک اسکالر باینری است، یعنی آن که اگر تحریک موجود باشد مقدار ورودی p مساوی ۱ و اگر تحریک موجود نباشد p برابر ۰ خواهد بود. خروجی نرون a نیز تنها دلالت بر وجود، یا عدم وجود پاسخ خواهد داشت. وجود ارتباط خاص بین محرک و پاسخ نرون، توسط مقدار وزنه سیناپسی تعیین می‌شود. نرون در صورتی به محرک پاسخ می‌دهد که مقدار وزنه سیناپسی w ، بیشتر از مقدار بایاس b باشد.

□ قوانینی که در این بخش مورد بررسی قرار می‌گیرند، عموماً در چارچوب یک شبکه بزرگتر مورد استفاده قرار خواهند گرفت. جهت نمایش عملکرد این قوانین یادگیری انجمنی، از شبکه‌های ساده با دو نوع ورودی استفاده می‌کنیم، بدین صورت که نوع اول محرک‌های غیرمشروط و نوع دیگر محرک‌های شرطی را نمایندگی می‌کنند.



قانون یادگیری بدون ناظر هب

□ مقدمه

□ جمله معروف دونالد هب را همراه با داستان سگ پاولوف به یاد آورید. محرك شرطي، همان زنگوله و محرك غير شرطي، غذا را نمایندگي مي کند. در آغاز سگ تنها با رویت غذا اشتهايش تحريك مي شود، در اين جا ورودی محرك شرطي را با P_c و ورودی محرك غير شرطي را با P_u نمایش مي دهيم.

□ بطور كلي براي مسائل پیچیده به شبکه های نیازمندیم که توانایی یادگیری ارتباطها را داشته باشند.

□ مثال: تبلیغاتی را که ضد سیگار می شود در نظر می گیریم: سیگار کشیدن مترادف با مرگ تدریجی است. اگر مدتی این دو تصویر (کشیدن سیگار و مرگ تدریجی) همزمان نمایش داده شوند، پس از زمان کوتاهی، هر وقت که سیگار نشان داده شود، تصویر مرگ زای آن به ذهن انسان القا می گردد. به عبارتی شکل سیگار پس از مدتی سیناپس ارتباطی بین ذهن و تصویر مرگ زایی سیگار را تقویت می کند. بطوری که اگر شکل مرگ زایی نیز همراه سیگار نباشد، رویت سیگار تصویر مرگ زایی آن را زنده می کند.



قانون یادگیری بدون ناظر هب

□ بیان ریاضی

- قانون بدون ناظر هب وزنه سیناپسی موجود بین ورودی p و خروجی نرون را متناسب با حاصل ضربشان تقویت می کند.


$$w(k) = w(k-1) + \alpha a(k) p(k)$$

- اکنون به مثال سیگار توجه می کنیم. هر زمان که $w_c > -b$ باشد، ارتباطی بین شکل سیگار و مرگ ایجاد می گردد، وقتی که شکل سیگار رویت شود $p_c = 1$ و آنگاه صرف نظر از این که تصویر مرگ زای آن رویت شود یا خیر، مقدار $a = 1$ خواهد بود.
- یک نکته قابل ذکر در این جا این است که قاعده یادگیری، تنها از سیگنالهای موجود در لایه ای که شامل وزن W است استفاده می کند (قانون یادگیری محلی).
- قانون یادگیری محلی بدون ناظر هب

$$\underline{w}(k+1) = \underline{w}(k) + \alpha \underline{a}(k+1) \underline{p}^T(k+1)$$

قانون یادگیری بدون ناظر هب

- علت به کارگیری اصطلاح بدون ناظر: در روابط مذکور از خروجی مطلوب استفاده نمی‌شود و یادگیری تنها در اثر ارائه یکسری ورودیها به شبکه صورت می‌پذیرد. (در هر تکرار، نخست خروجی در پاسخ به ورودی محاسبه شده و سپس بردار تنظیم می‌گردد)





قانون یادگیری بدون ناظر هب

□ مثال : قانون یادگیری بدون ناظر هب را برای مثال سیگار به کار می بریم

فرض: $\underline{w}(\cdot) = \begin{bmatrix} w_c(\cdot) \\ w_u(\cdot) \end{bmatrix} = \begin{bmatrix} 0 \\ 1 \end{bmatrix}, b = -\frac{1}{2}$

هدف: تنظیم پارامترهای منتسب به محرك شرطی.

ورودیهای مرجع را اعمال می کنیم:
 $\left\{ \begin{array}{l} (p_c(1) = 1, p_u(1) = 0), (p_c(2) = 1, p_u(2) = 1), \\ (p_c(3) = 1, p_u(3) = 0), \dots \end{array} \right\}$
فرض : w_u ثابت باقی مانده و w_c طبق رابطه فوق تنظیم می گردد:

$$w_c(k+1) = \underline{w}_c(k) + a(k+1).p_c(k+1)$$

$$w_c(1) = 0 + a(1).1 \quad a(1) = \text{sign}(w_u(0).p_u(1) + w_c(0).p_c(1) + b) = \text{Sign}(1 \times 0 + 0 \times 1 - 1/2) = 0$$



$$a(2) = \text{sign}(1 \times 1 + 0 \times 1 - \frac{1}{2}) = 1 \quad w_c(2) = w_c(1) + a(2).p_c(2) = 0 + 1 \times 1 = 1$$



$$a(3) = \text{sign}(1 \times 0 + 1 \times 1 - \frac{1}{2}) = 1 \quad w_c(3) = w_c(2) + a(3).p_c(3) = 1 + 1 = 2$$





قانون یادگیری بدون ناظر هب

- با قانون یادگیری بدون ناظر محلی هب، شبکه قادر است ارتباطها را بیاموزد.
- نکته مهم: با هر تکرار، عناصر بردار وزن بسیار بزرگ می شوند. با مراجعه به طبیعت بیولوژیک که قانون هب از آن الهام گرفته شده است، چنین موردی نیز از واقعیت دور است. پس عملاً یک مکانیسم محدود کننده در سیستم یادگیری احتیاج است. بدین منظور با استفاده از یک عبارت میرا قانون هب را بهبود می بخشیم.

$$\underline{w}(k) = \underline{w}(k-1) + \alpha a(k) \underline{p}^T(k) - \beta \underline{w}(k-1)$$

$$= (1 - \beta) \underline{w}(k-1) + \alpha a(k) \underline{p}^T(k)$$




دانشگاه صنعتی امیرکبیر
(پلی تکنیک تهران)

قانون یادگیری بدون ناظر هب، شبکه‌های اینستار و اوتستار

شبکه اینستار
قانون کوهنن

شبکه اینستار



□ شبکه اینستار

□ شبکه ی تشکیل شده از نرونهايي که ورودی آنها يك بردار باشد.

□ این ساده‌ترین شبکه‌اي است که قابلیت شناسایی الگو را داراست.

□ واضح است که نرون اینستار زمانی فعال خواهد شد که $n \geq 0$

□ و یا $wp \geq -b$ باشد. می دانیم $\langle \underline{w}, \underline{p} \rangle = \|\underline{w}\| \cdot \|\underline{p}\| \cos \theta$ زاویه بین

□ بردارهاي $\underline{w}, \underline{p}$ است.

□ نرون اینستار زمانی فعال خواهد بود که \underline{p} نزدیک \underline{w} باشد.

□ اگر $b = -\|\underline{w}\| \cdot \|\underline{p}\|$ باشد، آنگاه نرون اینستار به شرطی فعال خواهد شد که \underline{w} در همان جهتی

باشد که \underline{p} قرار داد.

□ نکته : هرچه مقدار b بزرگتر باشد، الگوهاي بیشتری برای فعال کردن نرون اینستار وجود

خواهند داشت، و به عبارت دیگر حساسیت نرون نسبت به الگوها کمتر می‌شود.



شبکه اینستار

- قانون یادگیری اینستار
- برای این که شبکه بتواند الگویی را بدون نظارت یاد بگیرد، نیاز به وضع قانون جدیدی است که تضمین کننده نرمالیزه شدن وزنه‌ها باشد.
- قانون هب چنین خاصیتی را تامین نمی‌کند. همچنین با اضافه کردن عبارت ترم میرا به قانون هب، ملزم به تحریک مداوم شبکه هستیم. یک راه برای اجتناب از این امر است که زمانی اجازه دهیم ترم میرا عمل کند که نرون اینستار فعال شده باشد ($a \neq 0$).
- یا عمل فراموش کردن الگوها حداقل شده باشد در این صورت:

$$w_j(k) = w_j(k-1) + \alpha a(k) p_j(k) - \beta a(k) w_j(k-1)$$

- اگر بخواهیم به یادگیری الگوهای جدید و فراموشی الگوهای قبلی به یک اندازه ارزش بدهیم، α را برابر β فرض می‌کنیم و خواهیم داشت:

$$w_j(k) = w_j(k-1) + \alpha a(k) [p_j(k) - w_j(k-1)]$$



شبکه اینستار

□ قانون یادگیری اینستار

$$\underline{w}(k) = \underline{w}(k-1) + \alpha [p(k) - \underline{w}(k-1)] = (1 - \alpha)\underline{w}(k-1) + \alpha p(k)$$


- وقتی نرون اینستار فعال است، بردار وزن در جهت بردار ورودی حرکت می‌کند.
- امتداد حرکت روی خطی است که بردار ورودی و بردار وزن را در لحظه قبل بهم متصل می‌کند.
- میزان طول قدم را در راستای خط اتصالی، پارامتر α تعیین می‌کند.
- $\alpha = 1$ هنگامی که نرون اینستار فعال گردید، بردار جدید وزن همان بردار الگو خواهد شد.
- $\alpha = 0.5$ بردار جدید، نصف راه بین بردار قدیم وزن و بردار الگو را طی می‌کند.
- در این جا اگر الگوهای ورودی نرمالیزه باشند، آنگاه بردار وزن هم پس از یادگیری يك الگوی ورودی بطور اتوماتیک نرمالیزه خواهد شد.



شبکه اینستار

□ قانون یادگیری اینستار

- قانون جدید اینستار که اساسا همان قانون هب است، نه تنها عمل فراموش نمودن الگوها را حداقل می‌کند، بلکه اگر ورودیها نرمالیزه باشند بردار وزنه‌ها هم نهایتا نرمالیزه می‌گردند.

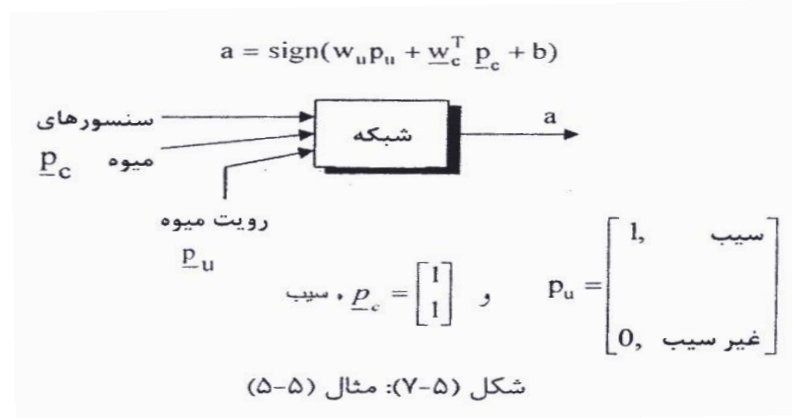


شکل (۵-۶) نمایش برداری قانون اینستار



شبکه اینستار


- مثال:
- شبکه شکل (۷-۵) را در نظر بگیرید. قانون اینستار را روی شبکه فوق اعمال کنید.
- جواب : شبکه دارای دو ورودی است. یک ورودی دلالت می‌کند بر این که آیا میوه مشاهده شده سیب یا غیر سیب است، (محرک غیرشرطی) و بردار ورودی دیگر دو ویژگی شکل و بافت میوه را بیان می‌کند. (محرک شرطی). خروجی شبکه برابر است با:



شبکه اینستار

□ مثال:

- عناصر بردار ورودی \underline{P}_c متعلق به مجموعه $\{-1, 1\}$ هستند. این تعلق تضمین می‌کند که بردار با طول $\sqrt{2}$ نرمالیزه باشد. ترم بایاس b را برابر -1 انتخاب می‌کنیم.



شکل (۸-۵): شبکه اینستار مثال ۵-۵

- همچنین برای این که شبکه یک ارتباط ثابت بین رویت سبب و پاسخ مربوطه داشته باشد، w_u را برابر مقداری بزرگتر از $-b$ قرار می‌دهیم. و چون می‌خواهیم که شبکه در آغاز به هیچ ترکیبی از مقادیر اندازه‌گیری شده از میوه پاسخ ندهد، مقدار اولیه $w_c(0)$ را مساوی 0 قرار می‌دهیم. نهایتاً شرایط اولیه زیر را داریم:

$$b = -1, w_u = 2, w_c(0) = [0 \ 0]^T$$



شبکه اینستار

□ مثال:

□ $\alpha = 1$

□ در تکرار اول خواهیم داشت:

$$\underline{w}_c(k) = \underline{w}_c(k-1) + \alpha a(k) \left[\underline{p}_c(k) - \underline{w}_c(k-1) \right]$$

$$a(1) = \text{sign}(w_u p_u + \underline{w}_c^T(0) \underline{p}_c(1) - 1) = \text{sign}\left(2 \times 0 + [0 \ 0] \begin{bmatrix} 1 \\ 1 \end{bmatrix} - 1\right) = 0$$

$$\underline{w}_c(1) = [0 \ 0]^T$$

□ در تکرار دوم خواهیم داشت:

$$a(2) = \text{sign}(w_u p_u(2) + \underline{w}_c(1) \underline{p}_c(2) - 1) = \text{sign}\left(2 \times 1 + [0 \ 0] \begin{bmatrix} 1 \\ 1 \end{bmatrix} - 1\right) = 1$$

$$\underline{w}_c(2) = \underline{w}_c(1) + a(2) \left[\underline{p}_c(2) - \underline{w}_c(1) \right] = [0 \ 0]^T + 1 \left(\begin{bmatrix} 1 \\ 1 \end{bmatrix} - \begin{bmatrix} 0 \\ 0 \end{bmatrix} \right) = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$$



شبکه اینستار

□ ادامه مثال:

در واقع بردار $\underline{w}_c(2)$ ، همانند بردار مشخصات سیب است. شبکه اکنون می‌تواند سیب را از روی اندازه‌هایش تشخیص دهد شبکه در تکرار سوم با وجود خطای رویتی، پاسخ خواهد داد. ($a=1$):

$$a(3) = \text{sign}(2 \times 0 + [1 \ 1] \begin{bmatrix} 1 \\ 1 \end{bmatrix} - 1) = 1 \quad \underline{w}_c(3) = \underline{w}_c(2) + a(3) [\underline{p}_c(3) - \underline{w}_c(2)]$$
$$= \begin{bmatrix} 1 \\ 1 \end{bmatrix} + 1 \left(\begin{bmatrix} 1 \\ 1 \end{bmatrix} - \begin{bmatrix} 1 \\ 1 \end{bmatrix} \right) = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$$

□ برادر وزن دیگر تغییر نخواهد یافت. و این بدین معنی است که شبکه بخوبی قادر شده است بردار اندازه‌ها را به پاسخ سیب مرتبط نماید. البته بایستی متذکر شویم که در این جا یادگیری به علت بزرگ بودن α سریع شده است.



شبکه اینستار

□ قانون کوهن:

□ قانون کوهن همانند قانون اینستار، وزن‌های نرون را طوری اصلاح می‌کند تا بردار ورودی "الگو" را یاد بگیرد. با این حال یادگیری از نوع کوهن متناسب با پاسخ نرون نیست.

□ قانون کوهن:

$$w_i(k) = w_i(k-1) + \alpha(p(k) - w_i(k-1)), i \in \Pi(k)$$

□ قانون کوهن نوعی از قوانین حافظه انجمنی می‌باشد. در اینجا یادگیری برای نرون‌های خاصی انجام می‌گیرد که دارای ویژگی‌های مخصوصی هستند. و با مجموعه $\Pi(k)$ مشخص می‌شوند. همان گونه که از نمایش مجموعه معلوم است این مجموعه‌ها با زمان تغییر می‌کند.

□ نکته: اگر قانون اینستار به لایه‌ای از نرون‌ها که دارای تابع تبدیل sign می‌باشد اعمال شود، آنگاه قانون کوهن عملاً معادل قانون اینستار می‌شود مشروط بر آن که $\Pi(k)$ برابر باشد با:

$$\Pi(k) = \{i \mid a_i(k) = 1\}$$



دانشگاه صنعتی امیرکبیر
(پلی تکنیک تهران)

شبکه‌های اوتستار


شبکه ساده بازیابی



شبکه ساده بازیابی

مقدمه

- اینستار با یک نرون عمل شناسایی الگو را انجام می دهد. این شبکه تک نرون یک بردار محرک را به یک پاسخ اسکالر ارتباط می دهد. شبکه اوتستار برعکس شبکه اینستار، دارای یک رودی اسکالر و یک بردار خروجی است.



شکل (۵-۹): شبکه اوتستار

- شبکه اوتستار، عمل بازیابی الگو را از طریق ایجاد ارتباط مابین محرک و بردار خروجی انجام می دهد. رابطه ورودی - خروجی شبکه فوق توسط رابطه بعد بیان می شود.
$$\underline{a} = \text{ssatl}(\underline{wp})$$

- تابع غیرخطی ssatl ، بدین خاطر انتخاب شده است تا تمامی الگوها بین $[-1, 1]$ بازیابی شوند.



شبکه ساده بازیابی

- قانون یادگیری اوتستار
- جهت به دست آوردن قانون یادگیری اوتستار، از قانون اولیه هب استفاده می کنیم. در این جا ترم میرا را متناسب با ورودی شبکه P_j قرار می دهیم.

$$w_{ij}(k) = w_{ij}(k-1) + \alpha a_j(k) p_j(k) - \beta p_j(k) w_{ij}(k-1)$$

$$\alpha = \beta \quad \longrightarrow \quad w_{ij}(k) = w_{ij}(k-1) + \alpha (a_j(k) - w_{ij}(k-1)) p_j(k)$$

یادگیری زمانی اتفاق می افتد که P_j مخالف w_j باشد. وقتی که یادگیری صورت گیرد، بردار w_j به سمت بردار خروجی میل خواهد نمود:

$$\underline{w}_j(k) = \underline{w}_j(k-1) + \alpha [a(k) - \underline{w}_j(k-1)] P_j(k)$$




شبکه ساده بازیابی

□ مثال

شکل اندازه گیری شده

باقت اندازه گیری شده

سیب شناسایی شده



شکل (۵-۱۰) شبکه بازیابی سیب

شبکه شکل زیر را در نظر بگیرید.

شبکه دارای دو ورودی است، بردار \underline{P}_c به عنوان

بردار محرک شرطی، معرف پاسخ سنسورها

(مشخصات میوه) بوده و P_u رویت یا عدم رویت

سیب را نشان می دهد. (محرک غیر شرطی)

خروجی شبکه بردار مشخصات میوه را منعکس می کند.

ماتریس وزنی برای محرک غیر شرطی، W^u ، برابر ماتریس واحد قرار داده می شود تا هر مجموعه

مشخصات \underline{P}_u (با مقادیر) در خروجی ظاهر شود. ماتریس وزنی برای محرک شرطی W^c

در آغاز برابر ۰ قرار داده می شود. بطوری که اگر $P_u = 1$ باشد، پاسخی در شبکه ظاهر نشود

ماتریس W^c مطابق رابطه زیر تنظیم می شود:

$$49 w_{j,1}^c(k) = w_{j,1}^c(k-1) + [a_j(k) - w_{j,1}^c(k-1)] p_c(k), j = 1, 2$$



شبکه ساده بازیابی

□ ادامه ی مثال

$$W^c(\cdot) = \begin{bmatrix} \cdot \\ \cdot \end{bmatrix} W^u = \begin{bmatrix} 1 & \cdot \\ \cdot & 1 \end{bmatrix}$$

□ مجموعه داده‌های یادگیری، شامل ارائه مکرر علامت رویت و بردار مشخصات سیب هستند.
بردار مشخصات سیب را به صورت $\underline{P}_c = [1 \ 1]^T$ در نظر می‌گیریم فرض می‌کنیم بردار تکرارهای زوج اندازه‌گیری مشخصات میوه صحیح عمل می‌کند. به عبارتی:

$$\left[\left(\underline{P}_c(1) = \begin{bmatrix} \cdot \\ \cdot \end{bmatrix} P_u(1) = 1 \right) \text{ و } \left(\underline{P}_c(2) = \begin{bmatrix} 1 \\ 1 \end{bmatrix} P_u(2) = 1 \right) \text{ و } \dots \right]$$

$$\underline{a}(1) = \text{ssatl}(w^u \underline{p}_u(1) + w^c p_c(1))$$

در تکرار اول ($k=1$) سیب رویت می‌شود:

$$= \text{ssatl} \left[\begin{bmatrix} 1 & \cdot \\ \cdot & 1 \end{bmatrix} \begin{bmatrix} \cdot \\ \cdot \end{bmatrix} + \begin{bmatrix} \cdot \\ \cdot \end{bmatrix} 1 = \begin{bmatrix} \cdot \\ \cdot \end{bmatrix} W^c(1) = W^c(0) + (\underline{a}(1) - W^c(0)) p_c(1) = \begin{bmatrix} 0 \\ 0 \end{bmatrix} \right]$$

مشخصات صحیح موجود نیست و داریم:



شبکه ساده بازیابی

□ ادامه ی مثال

□ در تکرار دوم ($k=2$) سیب رویت شده و بردار مشخصات هم صحیح است. بنابراین:

$$\underline{a}(2) = \text{ssatl} \left(\begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} 1 \\ 1 \end{bmatrix} + \begin{bmatrix} 0 \\ 1 \end{bmatrix} \cdot 1 \right) \begin{bmatrix} 1 \\ 1 \end{bmatrix} \quad W^c(2) = \begin{bmatrix} 0 \\ 0 \end{bmatrix} + \left(\begin{bmatrix} 1 \\ 1 \end{bmatrix} - \begin{bmatrix} 0 \\ 0 \end{bmatrix} \right) p_c(2) = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$$

□ در تکرار سوم ($k=3$) بردار مشخصات نادرست است، خروجی شبکه برابر است با:

$$\underline{a}(3) = \text{ssatl} \left(\begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} 0 \\ 0 \end{bmatrix} + \begin{bmatrix} 1 \\ 1 \end{bmatrix} \cdot 1 \right) = \begin{bmatrix} 1 \\ 1 \end{bmatrix} \quad W^c(3) = W^c(2) + (\underline{a}(3) - W^c(2)) p_c(3) = \begin{bmatrix} 1 \\ 1 \end{bmatrix} + 0 \cdot 1 = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$$

□ بردار مشخصات در خروجی شبکه بازیابی شد. یعنی هر زمانی که سیب رویت شود و بردار اندازه‌ها هم موجود نباشند، شبکه قادر به بازیابی بردار اندازه‌های سیب در خروجی خود خواهد بود.



شبکه ساده بازیابی

نکات:

۱: گنجایش ذخیره سازی شبکه‌های خود انجمنی نمی‌تواند بزرگتر از بعد شبکه گردد. اگر الگوها از هم مستقل آماری باشند، طبق قضیه حد مرکزی دارای توزیع گوسی خواهد بود. همچنین در این حالت می‌توان از روش متعامد سازی گرام اشمیت استفاده نمود و بردارهای متعامدی با طول واحد ساخت و سپس شبکه حافظه انجمنی را مورد استفاده قرار داد.

۲: يك شبکه حافظه انجمنی را می‌توان به دو نوع مختلف دیگر، با نامهای خطی و غیرخطی تقسیم نمود. واضح است که این تقسیم بندی به نوع تابع تبدیل نرونهاي شبکه بستگی دارد. برای حالت خطی، در بخشهای قبل دیدیم که رفتار شبکه‌های حافظه انجمنی با معادله $\underline{a} = W\underline{P}$ توصیف می‌شود. در حالت غیرخطی، رابطه ورودی - خروجی شبکه به شکل زیر بیان می‌شود:

$$\underline{a}(k+1) = \underline{f}(W, \underline{a}, p; k)$$

شبکه‌ها پدید، جز دسته اخیر از شبکه‌های حافظه انجمنی قرار دارد، که بعد تربطور گسترده مورد بررسی قرار می‌گیرد.



دانشگاه صنعتی امیرکبیر
(پلی تکنیک تهران)

شبکه های هایفاید

شبکه هایفاید گسسته



شبکه هایفیلد گسسته

- شبکه هایفیلد که جز شبکه‌های حافظه انجمنی است، جان هایفیلد (۱۹۸۲).
- هایفیلد محقق برحسته‌ای است که رنسانسی در شبکه‌های عصبی ایجاد نمود. او با استفاده از تابع انرژی و توسعه تئوریک آن توانست شبکه هایفیلد را با سیستم‌های دینامیکی فیزیکی مرتبط ساخته و از این طریق بعضی از مسائل بهینه‌سازی را با شبکه‌های عصبی حل نماید تعمیم این شبکه‌ها در بخش‌های بعدی ارائه می‌گردد.

گسسته (اجتماع نرونهاي كاملا مرتبط بهم) هر نرون مقاديري را در بازه^[11-] به عنوان ورودی دریافت می‌کند. خروجی هر نرون هم در بازه^[11+] است.


□ شبکه هایفیلد

پیوسته در ادامه توضیحات آورده می‌شود.



شبکه هایفیلد گسسته

□ شبکه هایفیلد:



شکل (۵-۱۱): بلوک دیاگرام شبکه هایفیلد گسسته

□ رابطه خروجی نرون:

$$\underline{a}(k+1) = ssign(W \underline{a}(k) + \underline{b})$$

$$\underline{a}(0) = \underline{p}$$



شبکه هایفیلد گسسته

- اختلاف شبکه ها پفیلد با دیگر شبکه ها : در شبکه هایفیلد تمامی نرونها همانند یکدیگر عمل می کنند و تقسیم بندی نرونهاي ورودی و خروجی وجود ندارد.
- شبکه هایفیلد، شبکه ای است کاملاً برگشتی که در آن خروجی هر نرون به ورودی تمام نرونهاي دیگر متصل است.
- پس از اعمال ورودیها که همگی به مجموعه $\{-1, 1\}$ متعلقند و به عبارتی $\underline{p} \in \{-1, 1\}^{S \times 1}$ به شبکه، خروجی آن محاسبه شده و در قدم بعد به عنوان ورودی جدید به شبکه اعمال می شود. این امر آنقدر تکرار می شود تا خروجی شبکه به يك نقطه ثابت همگرا شود.
- توجه داریم که در این جا شبکه به عنوان يك سیستم دینامیکی عمل می کند و همگرایی یعنی رسیدن پاسخ شبکه به جوابی که بر اثر تکرار شبکه تغییر نمی کند و به عبارت دیگر گویند شبکه به حالت ماندگار خود رسیده است.

$$E(k) = -\underline{a}^T(k) W \underline{a}(k) - \underline{a}^T(k) I + \underline{a}^T(k) L$$




شبکه هایفیلد گسسته

- نحوه عملکرد شبکه هایفیلد
- تابع انرژی شبکه : با ملاحظه منحنی تابع انرژی شبکه در می یابیم که این منحنی دارای حفره هایی است که می توانند به عنوان مکان ذخیره سازی الگوهای شبکه مورد استفاده قرار گیرد. این حفره ها در واقع نقاط جذب شبکه هستند. نقطه های جذب به بیان ریاضی نقاط پایدار جانبی هستند و در شبکه هایفیلد، نقاطی هستند که شبکه به آنها همگرا می شود.
- توصیف هندسی مساله همگرایی را با توجه به شکل اسلاید بعد بیان می کنیم. نقطه ورودی که وضعیت اولیه بردار حالت شبکه را مشخص می کند به سمت کوچکترین ناحیه ای که شامل یکی از حفره های جذب می باشد نزدیک می شود و هنگامی که داخل محوطه قرار گرفت از هر طرف که حرکت کند نقطه جذب آن را به سمت خود می کشاند و نهایتاً نقطه ورودی جذب حفره می شود و در همان جا ایست خواهد نمود. چرا که هر جایی دیگری در حول و حوش آن نقطه دارای سطح شیب مثبت (جهتگیری به طرف بالا) است.

شبکه هایفید گسسته

□ نحوه عملکرد شبکه هایفید



شکل (۵-۱۲): تابع انرژی شبکه با یک نرون که در آن A و B نقاط جذب شبکه اند

□ نکته: برای شبکه هایفید، قدمهای بینابین که به نقاط جذب منتهی می شوند از قبل مشخص نیستند. از این رو احتیاج است که اطلاعات موثر بیشتری علاوه بر ساختار شبکه در اختیار باشد. این اطلاعات در شاخصی به نام تابع معیار انرژی خلاصه می شود. فرم کلی تابع انرژی شبکه هایفید به صورت زیر است:

$$E(k) = -\underline{a}^T(k) W \underline{a}(k) - \underline{a}^T(k) I + \underline{a}^T(k) L$$



شبکه هایفید گسسته

□ نحوه عملکرد شبکه هایفید

$$\underline{a} = [a_1, \dots, a_s]^T \quad w = [W]_{s \times s}$$

$$L = [1_1, \dots, 1_s]$$

$$I = [I_1, \dots, I_s]^T$$

□ مقدار آستانه نرون λ

□ بردار ورودی و یا بردار حالت شبکه در لحظه اولیه:

□ خروجی نرون a_i است.

□ w_{ij} وزنه اتصالی بین گره های i, j است.

وزنه های w_{ij} شامل اطلاعات مربوط به الگوها هستند و به همین خاطر به آنها وزن های حافظه ای می گویند. به عبارت دیگر همه الگوها در تابع معیار انرژی منظور شده اند. در شبکه هایفید کلاسیک ارتباطی بین نرون ها متقارن است.

یعنی $w_{ij} = w_{ji}$ و نرون ها به خودشان متصل نمی شوند.



شبکه هایفیلد گسسته

- ذخیره سازی الگو
- جهت ذخیره سازی يك الگو، لازم است که مقدار تابع انرژی در نقطه متناظر با بردار الگو، حداقل باشد به عبارت دیگر هر يك از الگوهاي مورد نظر يك نقطه حداقل را در منحنی تابع انرژی شبکه هایفیلد اشغال می‌کند.
- در همین حال مایلیم که در صورت ذخیره سازی الگوهاي جدید، الگوهاي قبلي به عنوان نقاط حداقل محلي، دستخوش تغییر نگردند. نظر بر این که ماتریس وزن شامل اطلاعاتی درباره الگوهاي ذخیره شده است، می‌خواهیم این ماتریس را به نحوی محاسبه نماییم که مقدار حداقل تابع انرژی را در نقاط متناظر با الگوها به همراه داشته باشد.
- به زبان ریاضی مایلیم که تابع انرژی برای يك مجموعه از الگوهاي خاص که هر يك دارای S عنصر به صورت $P \in \{-1,1\}^{S \times 1}$ هستند، حداقل گردد.
- نظر به اینکه ماتریس حافظه را می‌توانیم بطور تکراری به دست آوریم:

$$W^k = W^{k-1} + f(\underline{p}^q)$$



شبکه هایفیلد گسسته

- ذخیره سازی الگو
- که در این جا f تابعی است از الگوی \underline{p}^q . تابع انرژی را می توان برای هر الگوی \underline{p}^q به دو بخش زیر تقسیم نمود:
- بطوری که $E_q(k)$ انرژی است که با در نظر گرفتن الگوی \underline{p}^q به دست می آید. این تاثیر باید خود را در ماتریس W نشان دهد.
- با فرض $\underline{b} = 0, \underline{I} = 0$ تابع معیار انرژی را به صورت زیر می نویسیم:
$$E(k) = -\sum_i \sum_j w_{ij}^{k-1} a_i(k) a_j(k) - \sum_i \sum_j w_{ij}^q a_i(k) a_j(k)$$
- ترم اول را $E_q(k)$ و ترم دوم را $E_q(k)$ می نامیم. چون می خواهیم برای هر الگوی q , $E(k)$ حداقل شود، در این صورت تنها قادر به تاثیر گذاری روی w_{ij}^q هستیم. زیرا ترم اول بستگی به الگوی قبلی دارد که از دسترس خارج است. حداقل کردن $E(k)$ معادل است با حداکثر کردن $-E_q(k)$.
- با در نظر گرفتن $E_q(k)$ که عبارت است از:
$$-E_q(k) = \sum_i \sum_j w_{ij}^q a_i(k) a_j(k)$$



شبکه هایفیلد گسسته

□ ذخیره سازی الگو

□ هدف: برای الگوی $\underline{p}^q = [p_1^q \dots p_s^q]^T$ پارامترهای w_{ij}^q طوری پیدا شود که عبارت فوق حداکثر شود. یعنی $-E_q$ را حداکثر کنیم.

$$-E_q = \sum_i \sum_j w_{ij}^q p_i^q p_j^q$$

□ چون $p_i^q \in \{-1, 1\}$ می باشد، شرط کافی برای حداکثر شدن عبارت فوق این است که $w_{ij}^q p_i^q p_j^q = 1$ و یا به عبارتی $w_{ij}^q = p_i^q p_j^q$ شود. اگر این نتیجه را به تمامی الگوهای $q=1, \dots, Q$ (در این جا فرض کردیم که مایلیم Q الگو را ذخیره نماییم) تعمیم دهیم، عناصر ماتریس حافظه w را می توان مطابق رابطه زیر بدست آورد.

$$w_{ij} = \sum_{q=1}^Q w_{ij}^q = \sum_{q=1}^Q p_i^q p_j^q$$



شبکه هایفید گسسته

□ الگوریتم هایفید گسسته

□ مرحله اول: مقدار اولیه شبکه را با ورودی مشخص می کنیم:

$$\underline{p} \in \{-1,1\}^{s \times 1} \quad \text{و} \quad \underline{a}(\cdot) = \underline{p}$$

□ مرحله دوم : محاسبه عناصر ماتریس حافظه به صورت:

$$w_{ij} = \sum_{q=1}^Q p_i^q p_j^q \quad i, j = 1, 2, \dots, S$$

□ مرحله سوم : تکرار فرمول زیر تا حصول همگرایی :

$$a_i(k+1) = \text{ssign} \left(\sum_{j=1}^S w_{ij} a_j(k) \right), \quad i = 1, \dots, S$$



شبکه هایفیلد گسسته

□ بازیابی اطلاعات

- فرض کنید که می‌خواهیم مجموعه الگویی باینری $\{p^1, \dots, p^s\}$ را پس از ذخیره سازی بازیابی کنیم. بطوری که $p^i \in \{-1, 1\}^{s \times 1}$ و این که می‌دانیم:

$$n_i(k) = \sum_{j=1}^s w_{ij} a_j(k) + b_i \quad i = 1, \dots, S$$

$$a_i(k) = \begin{cases} 1 & n_i > 1_i \\ n_i & n_i = 1_i \\ -1 & n_i < 1_i \end{cases}$$

- تابع انرژی به شکل زیر تعریف می‌شود:

$$E(k) = -\sum_i \sum_j a_i(k) w_{ij} a_j(k) - \sum_i b_i a_i(k) + \sum_i l_i a_i(k)$$

- قضیه : هر تغییری در a در خلال پردازش موجب کاهش E خواهد شد.



شبکه های پیلد گسسته

- **بازیابی اطلاعات**
- نتیجه از قضیه: هر تغییری که توسط توابع غیر خطی ssign بر روی خروجی نرونها صورت گیرد، منجر به کاهش مقدار تابع انرژی خود خواهد شد.
- به عبارتی این شبکه همانند روش کاهش گرادیان در فضای E عمل می کند. و عملکرد آن باعث ارزیابی الگوی مورد نظر می گردد.
- در این جا متغیرهای حالت شبکه های پیلد، در هر تکرار در حوزه زمان که منجر به تغییر مقدارشان می شود، باعث کاهش یافتن مقدار تابع انرژی E می گردند و این کاهش آن قدر ادامه می یابد تا دیگر در تکراری جدید، تغییری در بردار حالت شبکه ایجاد نشود. (حالت ماندگار شبکه)
- الگوی تشکیل شده از متغیرهای حالت ماندگار، عموماً متناظر با یکی از الگوهای ذخیره شده می گردد و بدین خاطر گویند که الگوها بازیابی شده اند.



شبکه هایفیلد گسسته

□ خلاصه

□ در شبکه هایفیلد: الگوهای ورودی توسط بردارهایی نمایندگی می شوند که تابع انرژی در آن نقاط حداقل می شود. (الگوها نقاط پایدار مجانبی شبکه را تشکیل می دهند). (اگر یک بردار نامشخص همانند \underline{p} به عنوان ورودی به شبکه اعمال شود $(\hat{p} = \underline{p} + \Delta p)$ بطوری که \underline{p} یکی از بردارهای ذخیره شده باشد، آنگاه شبکه هایفیلد وقتی به بردار الگوی \underline{p} همگرا خواهد شد که Δp به اندازه کافی کوچک باشد.)

□ مشکلات پیاده سازی شبکه های حافظه انجمنی توسط شبکه هایفیلد:

- ۱- شبکه هایفیلد ممکن است به نقاطی همگرا شود که جزء هیچ یک از الگوهای مطلوب نباشد. به عبارت دیگر شبکه ممکن است به الگوهای ناخواسته و نامطلوب همگرا شود.
- ۲- با تخصیص الگوهای مطلوب به نقاط جذب تابع انرژی، دامنه نواحی شامل این نقاط باید به نحوی کنترل شود.

□ برای طراحی شبکه های عصبی که بتوانند در زمینه عمل حافظه انجمنی مفید باشند به شناخت کاملی از سیستم های دینامیکی با ابعاد وسیع و پایداری آنها نیازمندیم.



شبکه هایفیلد گسسته

□ روش نوینی برای ذخیره سازی الگو

□ سنتز جدیدی برای ذخیره سازی الگوها. (مهندس نوید سیفی پور ۱۳۷۵)

□ تابع انرژی ذکر شده در بخش قبلی با روش جدید نیز سازگار است و می تواند الگوها را در نقاط حداقل انرژی خود ذخیره کند. نشان داده شده است که این روش جهت سنتز شبکه هایفیلد در مقایسه با قانون هایفیلد از حجم بیشتر ذخیره سازی اطلاعات و سرعت همگرایی بالاتر برخوردار باشد.

□ روش جدید با روابط زیر خلاصه می گردد:

$$t_{ij} = \prod_{s=1}^L (a_i^s + a_j^s), \quad W = T^T T, \quad T = [t_{ij}], \quad W = [w_{ij}]$$

□ ماتریس W حافظه انجمی جدید بوده و ماتریس W sparse می باشد.

□ قضیه : هر تغییری در a در خلال پردازش موجب کاهش E به اندازه $\Delta E = -2\Delta a_k \sum_i a_i w_{ik}$ خواهد شد.


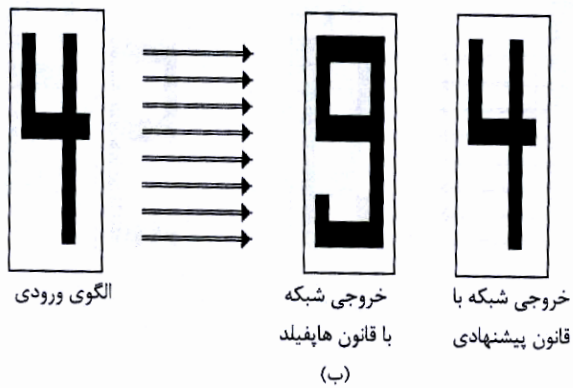




شبکه هایفیلد گسسته

- روش نوینی برای ذخیره سازی الگو
- قضیه: هر تغییری در \underline{a} در خلال پردازش موجب کاهش E به میزان $\Delta E = -\epsilon \Delta a_k \sum_j a_j w_{kj}$ خواهد شد.
- مثال:
- در این مثال اعداد ۰ الی ۹ مورد بررسی قرار می‌گیرند. قرار است که این اعداد توسط شبکه هایفیلد ذخیره و بازیابی شوند. برای این کار هم قانون جدید و هم قانون کلاسیک هایفیلد مورد استفاده قرار می‌گیرند.
- هدف: بررسی و مقایسه عملکرد دو قانون می‌باشد. با مشاهده شکل‌های اسلاید بعد، براحتی می‌بینیم که قانون کلاسیک هایفیلد در شناسایی این اعداد به مراتب از خطای بیشتری برخوردار می‌باشد. شبکه هایفیلد با استفاده از این قانون تمامی اعداد را به عنوان عدد ۹ بازیابی می‌نماید، در حالی که قانون پیشنهادی ما تمامی الگوهای ورودی را حتی با ده درصد نویز بدرستی شناسایی می‌کند. در مورد گنجایش ذخیره سازی قانون جدید و قانون کلاسیک هایفیلد و دلایل تئوریک برتری قانون پیشنهادی به تفصیل در جلد دوم کتاب شبکه‌های عصبی بحث خواهد شد.



شبکه هایفیلد گسسته



شکل (۵-۱۳): بهبود شبکه هایفیلد با قانون پیشنهادی



شبکه هایفیلد گسسته



الگوی ورودی



الگوی ورودی با ده درصد نویز خروجی شبکه با قانون پیشنهادی



الگوی ورودی



الگوی ورودی با ده درصد نویز



خروجی شبکه با قانون پیشنهادی

(ب)

شکل (۵-۱۴): بهبود شبکه هایفیلد با قانون پیشنهادی برای ورودی با ۱۰٪ نویز



از توجه شما
متشکرم