



شبکه‌های عصبی مصنوعی

درس ۱۸

شبکه‌ی گراسبرگ

Grossberg Network

کاظم فولادی قلعه
دانشکده مهندسی، پردیس فارابی
دانشگاه تهران

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



Grossberg Network

شبکه‌ی گراسبرگ

GROSSBERG NETWORK

شبکه‌ی گراسبرگ: در ادامه‌ی مباحث مربوط به الگوریتم‌های یادگیری رقابتی و انجمنی

شبکه‌ی گراسبرگ: نوعی شبکه‌ی رقابتی خود-سازماند پیوسته-زمان؛
با الهام از سیستم بینایی انسان؛
پایه و اساس شبکه‌های نظریه‌ی تشدید وقفی (ART)

گراسبرگ، از پژوهشگران پرکار دوره‌ی افت پژوهش بر روی شبکه‌های عصبی (اواخر 1960 و اوایل 1970) بود.
گراسبرگ، از ریاضیات غیرخطی برای مدل‌سازی کارکردهای خاص مغزی استفاده می‌کرد.

نکته‌ی مهم:

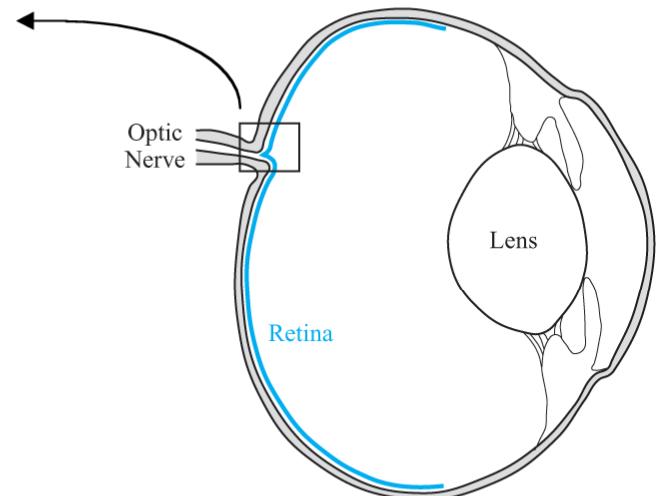
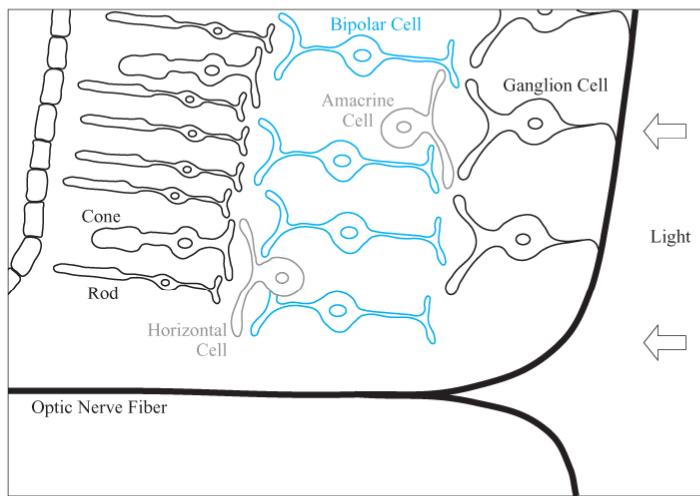
حوزه‌ی شبکه‌های عصبی، مخلوطی از زمینه‌های زیست‌شناسی، ریاضی و روان‌شناسی است و
شناخت دقیق مفاهیم شبکه‌های عصبی نیازمند کنکاش در چنین زمینه‌هایی است.

شبکه‌ی گراسبرگ

۱

انگیزش بیولوژیکی: بینایی

Biological Motivation: Vision



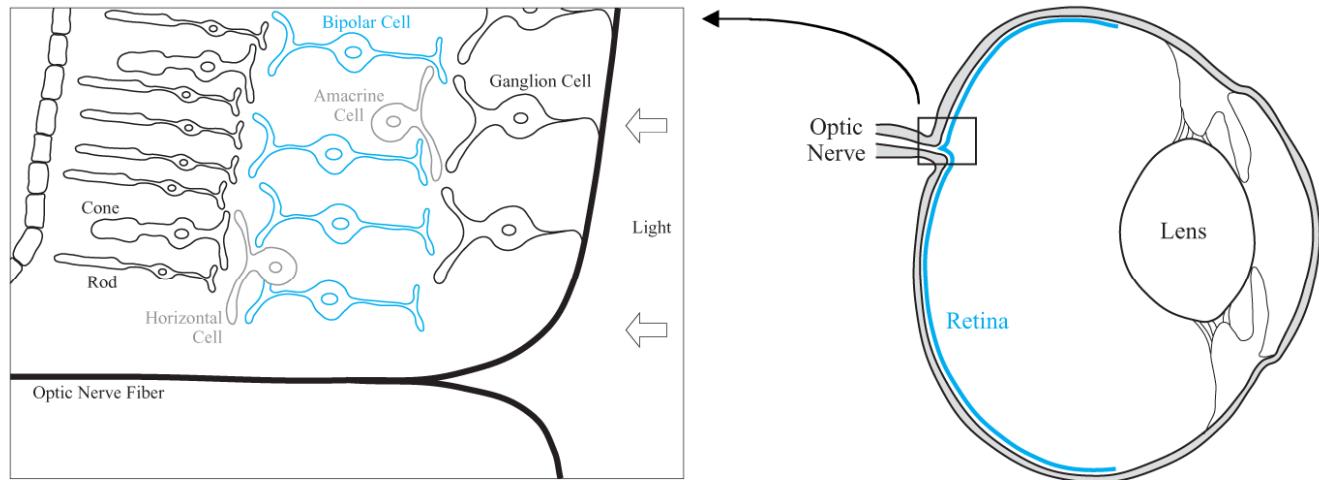
Eyeball and Retina

سیستم بینایی انسان

انگیزش بیولوژیکی شبکه‌های گراسبرگ

BIOLOGICAL MOTIVATION: VISION

نور از قرنیه و عدسی عبور کرده و توسط عدسی بر روی شبکیه متمرکز می‌شود.



پس از رسیدن نور به شبکیه،
فرآیند گسترده‌ی ترجمه‌ی اطلاعات نوری به یک تصویر قابل فهم برای انسان آغاز می‌شود.

Eyeball and Retina

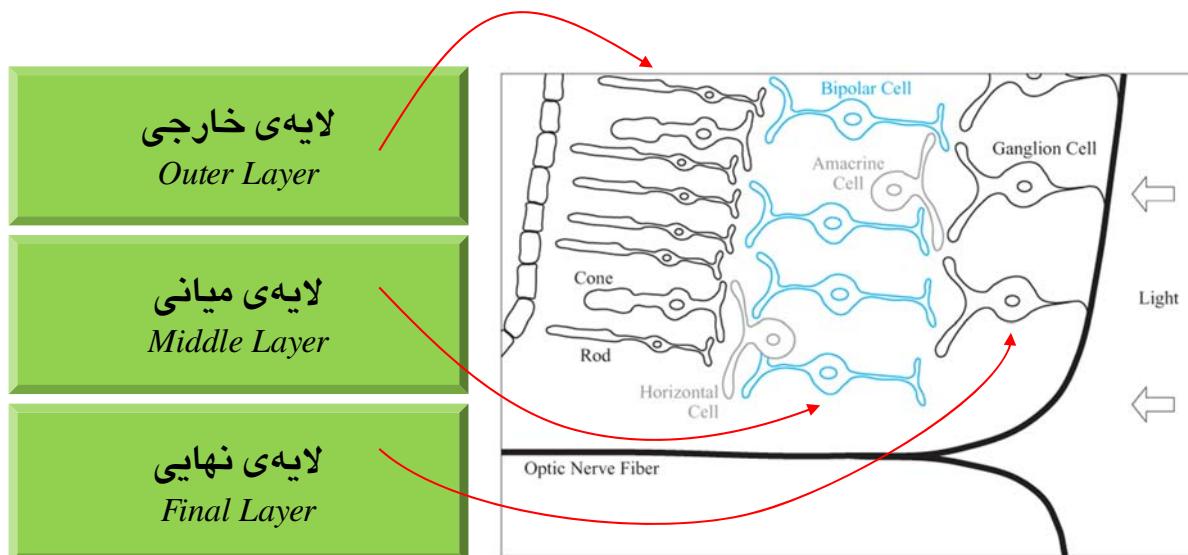
سیستم بینایی انسان

شبکیه

RETINA

شبکیه، در واقع قسمتی از مغز می‌باشد که در طی مراحل رشد جنین از مغز جدا می‌شود، اما اتصال بین شبکیه و مغز از طریق عصب‌های بینایی برقرار است.

شبکیه دیواره‌ی داخلی پشت چشم را می‌پوشاند و از سه لایه نرون تشکیل شده است:



Layers of Retina



The retina is a part of the brain that covers the back inner wall of the eye and consists of three layers of neurons:

Outer Layer:

Photoreceptors - convert light into electrical signals

Rods - allow us to see in dim light

Cones - fine detail and color

Middle Layer

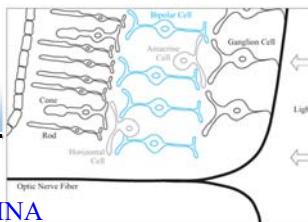
Bipolar Cells - link photoreceptors to third layer

Horizontal Cells - link receptors with bipolar cells

Amacrine Cells - link bipolar cells with ganglion cells

Final Layer

Ganglion Cells - link retina to brain through optic nerve



سیستم بینایی انسان

لایه‌های شبکیه

LAYERS OF RETINA

شامل سلول‌های گیرنده‌ی نور:
تبدیل نور به سیگنال‌های الکتریکی

لایه‌ی خارجی
Outer Layer

توانایی دیدن نور تاریک (*dim light*)سلول‌های میله‌ای (*Rods*)

گیرنده‌های نور
Photoreceptors

توانایی دیدن جزئیات ریز و رنگها

سلول‌های مخروطی (*Cones*)

به دلایل ناشناخته نور باید از دو لایه‌ی دیگر از شبکیه عبور کند
تا سلول‌های میله‌ای و مخروطی تحریک شوند: لایه‌ی میانی و لایه‌ی نهایی

لایه‌ی میانی
Middle Layer

اتصال‌دهنده‌ی گیرنده‌های نور به لایه‌ی نهایی

سلول‌های دوقطبی (*Bipolar Cells*)

اتصال‌دهنده‌ی بین گیرنده‌ها و سلول‌های دوقطبی

سلول‌های افقی (*Horizontal Cells*)

اتصال‌دهنده‌ی سلول‌های دوقطبی با سلول‌های لنفاوی لایه‌ی نهایی

سلول‌های آماکراین (*Amacrine Cells*)

متشكل از سلول‌های لنفاوی: آکسون سلول‌های لنفاوی از سطح شبکیه عبور کرده و در کنار هم جمع شده‌اند و عصب‌های بینایی را شکل داده‌اند.

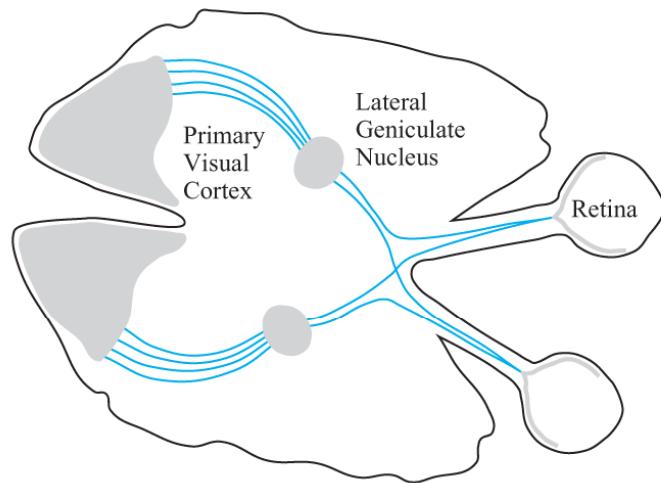
لایه‌ی نهایی
Final Layer

اتصال‌دهنده‌ی شبکیه به مغز از طریق عصب اپتیکی

سلول‌های لنفاوی (*Ganglion Cells*)

هر چشم از حدود ۱۲۵ میلیون سلول گیرنده‌ی نور تشکیل می‌شود، اما فقط ۱ میلیون سلول لنفاوی دارد
⇒ فرآیندهای قابل توجهی در شبکیه در راستای کاهش داده‌ها انجام می‌شود.

Visual Pathway

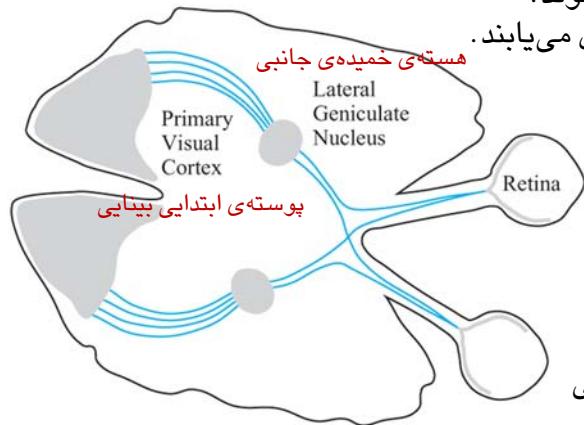


سیستم بینایی انسان

مسیر بینایی

VISUAL PATHWAY

آکسون‌های سلول‌های لنفاوی در قالب عصب‌های بینایی جمع شده و به قسمتی از مغز تحت عنوان «**هسته خمیده‌ی جانبی**» متصل می‌شوند. از این نقطه به بعد فیرها بر روی **پوسته‌ی ابتدایی بینایی** گسترش می‌یابند.



آکسون‌های سلول‌های لنفاوی با «**سلول‌های خمیده‌ی جانبی**» تشکیل سیناپس می‌دهند. همچنین «**سلول‌های خمیده‌ی جانبی**» با «**پوسته‌ی ابتدایی بینایی**» تشکیل سیناپس می‌دهند.

«**پوسته‌ی بینایی**» قسمتی از مغز است که مختص به کارکرد بینایی بوده و شامل لایه‌های متعدد است.

- اتصالات بین مسیرهای بینایی کاملاً غیرتصادفی است؛ نگاشت هر لایه به لایه‌ی بعدی کاملاً سازمان دهی شده است.
- آکسون‌های سلول‌های لنفاوی در قسمت خاصی از شبکیه به قسمت مشخصی از سلول‌های خمیده‌ی جانبی رفته و سپس به قسمت مشخصی از قشر بینایی متصل می‌شوند.
- به علاوه هر نیم‌کره اطلاعات ورودی را از هر دو چشم دریافت می‌کند (زیرا برخی فیرها از روی هم می‌گذرند و برخی بدون تقاطع هستند).

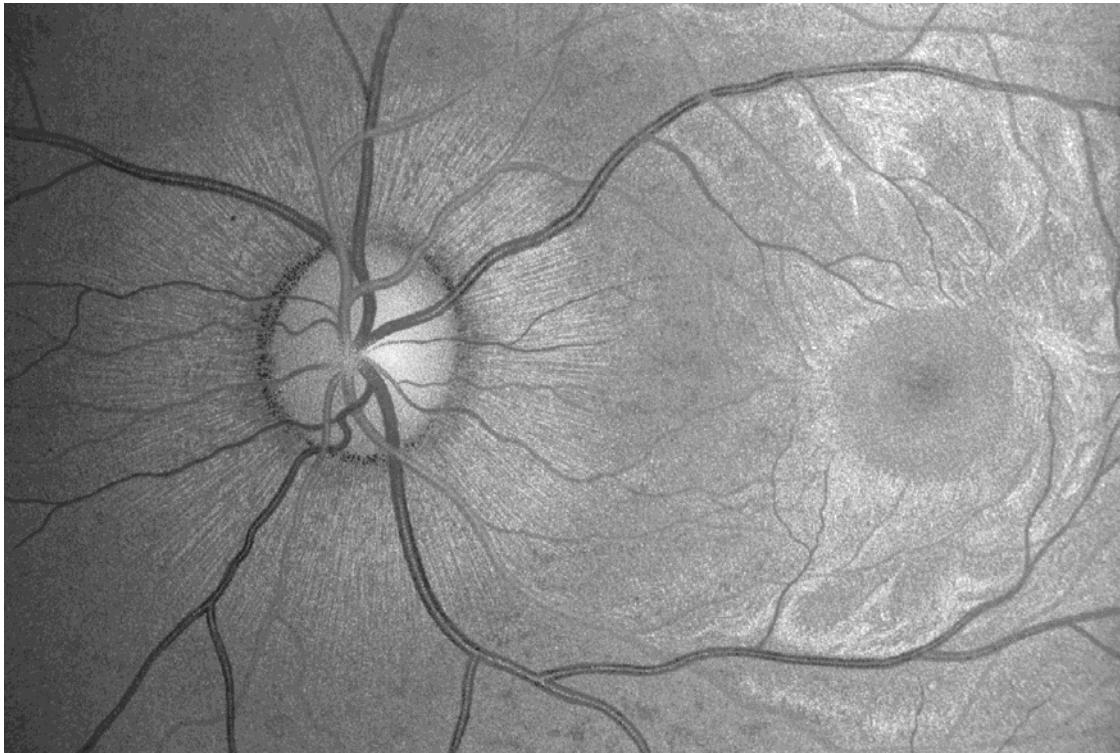
Photograph of the Retina



Blind Spot (Optic Disk)

Vein

Fovea

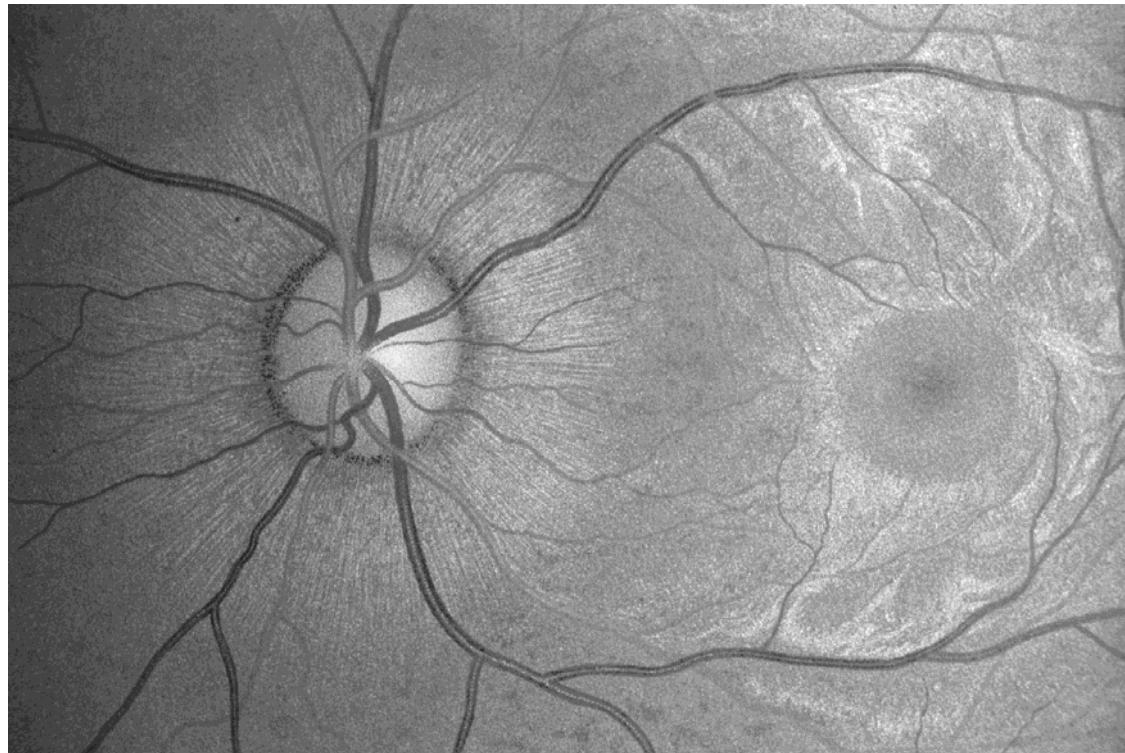


سیستم بینایی انسان

عکس شبکیه

PHOTOGRAPH OF THE RETINA

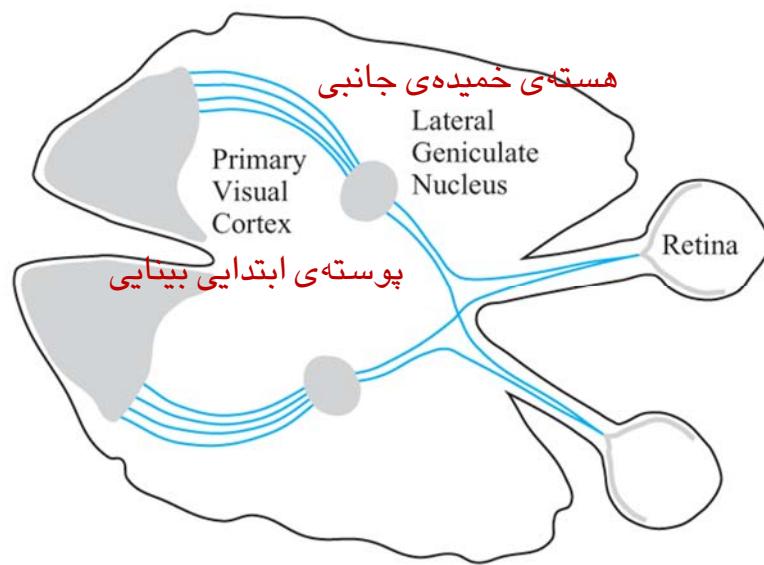
Blind Spot (Optic Disk) نقطه‌ی کور

Vein
رگFovea
لکه‌ی زرد

سیستم بینایی انسان

مسیر بینایی

VISUAL PATHWAY



اکنون یک ایده‌ی کلی در مورد ساختار و مسیرهای بینایی دریافت کرده‌ایم. اما:

- کارکرد بینایی چگونه انجام می‌شود؟

- هدف سه لایه‌ی شبکیه چیست؟

- چه عملیاتی توسط سلول‌های خمیده‌ی جانبی انجام می‌شود؟

برای پاسخ به این پرسش‌ها، باید **خطاهای دید** را بررسی کنیم.

سیستم بینایی انسان

نواقص درک شبکیه

IMPERFECTIONS IN RETINAL UPTAKE

علت وجود خطای دید چیست؟

نقص‌های موجود در فرآیند درک شبکیه موجب خطای دید می‌شود.

اگر بتوانیم یک مدل ریاضی را برای تولید خطاهای دید در سیستم بینایی توسعه دهیم، آن‌گاه ممکن است بتوانیم نحوه‌ی عملکرد قسمتی از مغز را توجیه نماییم.

نقص یک در سیستم ادرارکی شبکیه:

سلول‌های میله‌ای و مخروطی در نقطه‌ی کور وجود ندارند (علت شکل‌گیری نقطه‌ی کور) ما به طور عادی متوجه وجود این نقطه‌ی کور در چشممان نیستیم (به دلیل فرآیندهایی که در مسیر بینایی رخ می‌دهد).

آزمایش برای نقطه‌ی کور

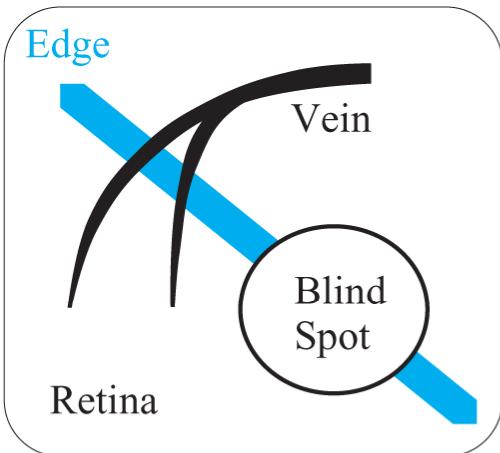
به دایره‌ی سمت چپ خیره شوید تا زمانی که چشم چپ شمارا به طور کامل پوشش دهد.

سپس با حرکت سر به این دایره نزدیک شوید و سپس به آرامی از آن دور شوید.

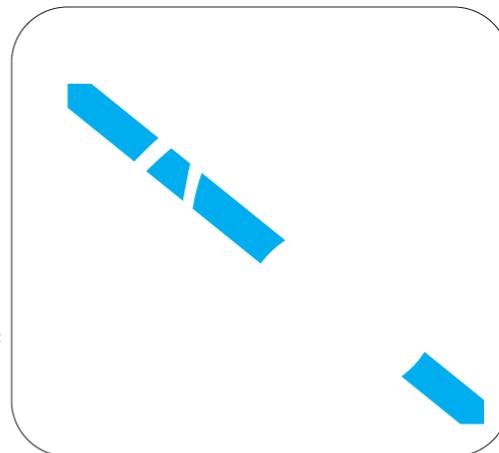
متوجه یک نکته می‌شوید: دایره‌ی سمت راست از دید شما محو می‌شود.

(* نکته‌ی جالب: ما دخالتی در انتقال تصویر به نقطه‌ی کور نداریم بلکه مغز ماست که مرتبک این اشتباه می‌شود.)

Imperfections in Retinal Uptake



Stabilized
Images Fade



سیستم بینایی انسان

نواقص درک شبکیه

IMPERFECTIONS IN RETINAL UPTAKE

نقص دو در سیستم ادرارکی شبکیه:

سرخرگ و سیاهرگ از مقابل گیرنده‌های نوری شبکیه عبور می‌کند.

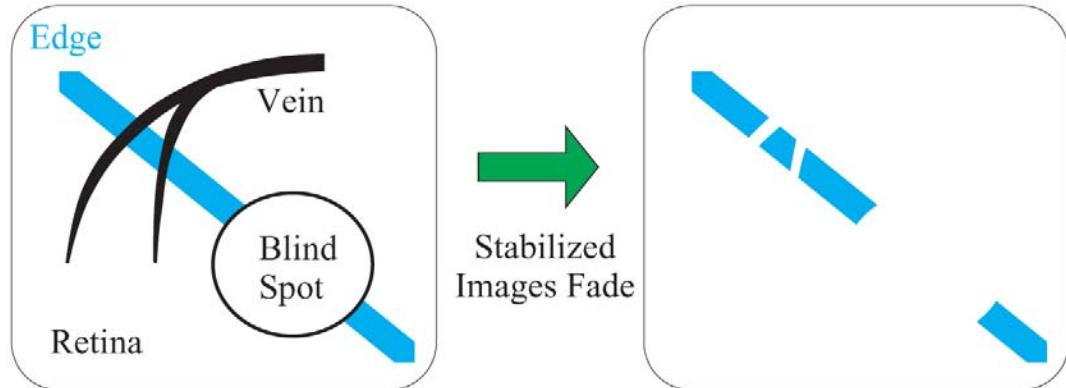
به‌این ترتیب از دریافت نور توسط سلول‌های میله‌ای و مخروطی در ناحیه‌ی بینایی جلوگیری می‌شود؛ به‌علاوه، از آنجا که گیرنده‌های نور شبکیه پشت دو لایه از شبکیه قرار دارند، نور ابتدا باید از این دو لایه عبور کند.

از آنجا که این نقاط فاقد سلول‌های گیرنده نور هستند، ما نمی‌توانیم رگ‌های داخل چشم خودمان را ببینیم.

به‌علاوه، کره‌ی چشم به‌طور طبیعی دارای تکان‌های ثابتی است ⇐

حتی یک جسم ثابت نیز متناسب با حرکت کره‌ی چشم در ناحیه‌ی بینایی ما متحرک می‌باشد.

* از آنجا که رگ‌ها نسبت به کره‌ی چشم ثابت هستند، بنابراین از ناحیه‌ی دید ما محو می‌شوند.



در این شکل لبه‌ی شبکیه نشان داده شده است.

حذف نواحی پوشیده شده توسط نقطه‌ی کور و رگ‌های چشمی از لبه‌ی شبکیه

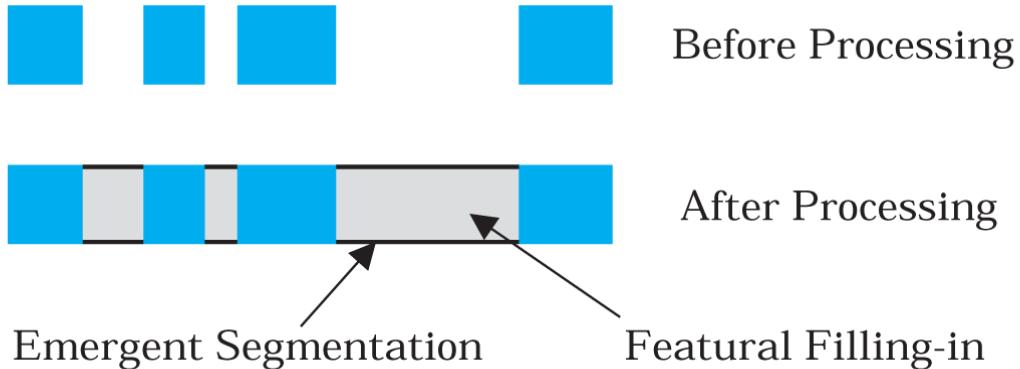


Emergent Segmentation:

Complete missing boundaries.

Featural Filling-In:

Fill in color and brightness.



سیستم بینایی انسان

پردازش جبران‌ساز

COMPENSATORY PROCESSING

از آنجا که ناحیه‌ی بینایی ما به دلیل وجود نقاط کور یاد شده دارای نقایص و کمبودهایی است، بنابراین سیستم عصبی ما باید این نقایص را با انجام یک سری عملیات خاص برطرف نماید و تصویر را کامل کند.
گراسبرگ در این ارتباط دو نوع اولیه از فرآیندهای جبران‌ساز را پیشنهاد کرده است:

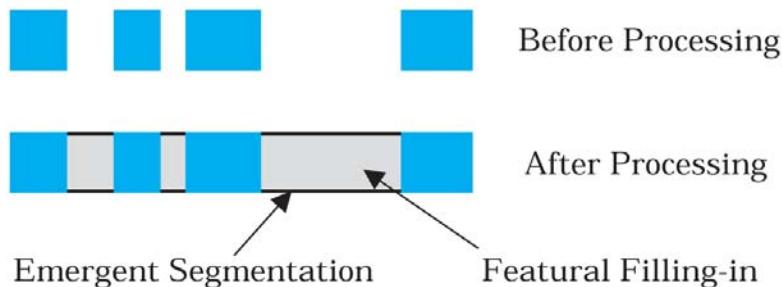
Emergent Segmentation:

Complete missing boundaries. قسمت‌های گمشده را تکمیل می‌کند.

Featural Filling-In:

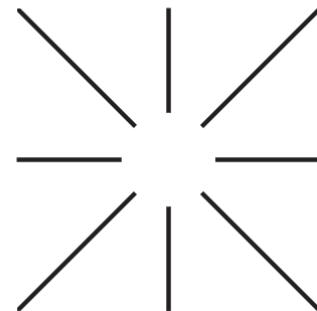
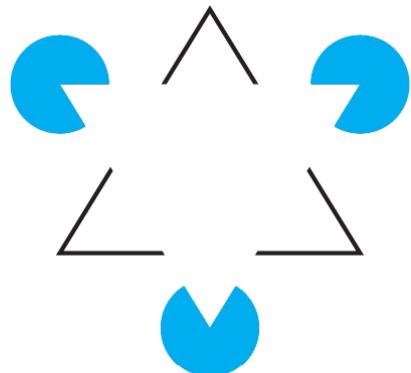
Fill in color and brightness.

قسمت‌های تولید شده را رنگ‌آمیزی کرده و روشنایی آنها را تنظیم می‌کند.



از آنجا که فرآیند ترسیم تصویری که ما می‌بینیم نیاز به زمان دارد، بنابراین امکان تشخیص دقیق قسمت‌های گمشده‌ی تصویر وجود ندارد
← شکل‌گیری خطای دید

Visual Illusions



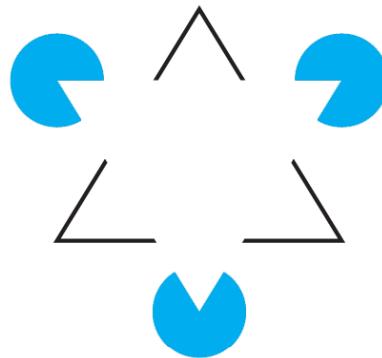
Illusions demonstrate the compensatory processing of the visual system. Here we see a bright white triangle and a circle which do not actually exist in the figures.

سیستم بینایی انسان

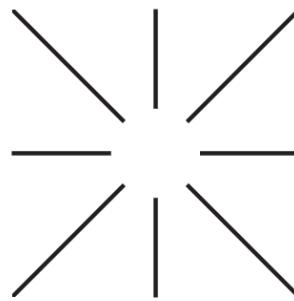
خطاهای دید

VISUAL ILLUSIONS

در اثر دو فرآیند جبران‌سازی



یک مثلث سفیدرنگ معکوس بر روی
سه دایره‌ی آبی اطراف آن دیده می‌شود.



یک دایره‌ی سفیدرنگ روی خطوط
دیده می‌شود.

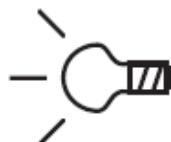
Illusions demonstrate the compensatory processing of the visual system. Here we see a bright white triangle and a circle which do not actually exist in the figures.

علاوه بر دو فرآیند جبران‌ساز، دو پدیده‌ی دیگر هم به سیستم بینایی پاری می‌رسانند:
ثبت روشنایی + کنترast روشنایی

Vision Normalization



Variable
Illumination



Separate
Constant Illumination



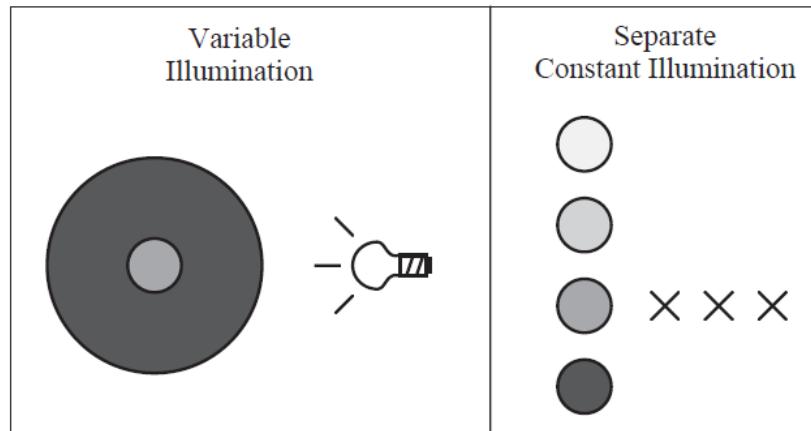
The vision systems normalize scenes so that we are only aware of relative differences in brightness, not absolute brightness.

سیستم بینایی انسان

نرمال‌سازی بینایی (تأثیر ثبات روشناختی در آزمایش)

VISION NORMALIZATION (BRIGHTNESS CONSTANCY)

یک دیسک خاکستری که در داخل یک دیسک تیره‌تر قرار گرفته است، به فرد مورد آزمایش نشان داده می‌شود و از او خواسته می‌شود تا میزان روشناختی دیسک مرکزی را از طریق انتخاب یک دیسک همنگ در میان دیسک‌های موجود، تعیین نماید.



سپس میزان نوری که به تصویر می‌تابد افزایش داده می‌شود و دوباره از فرد خواسته می‌شود دیسک همنگ را انتخاب کند.

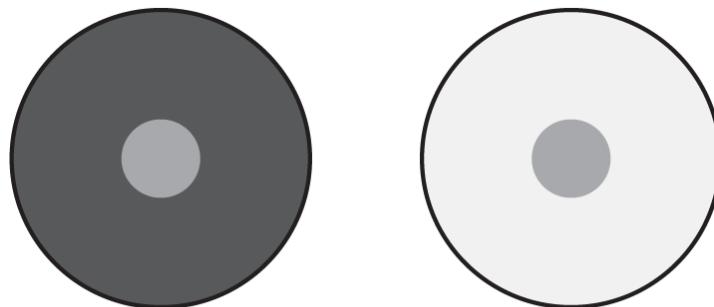
این فرآیند برای چند سطح نوری دیگر هم تکرار می‌شود.

در نتیجه‌ی این عملیات مشاهده می‌شود که فرد همیشه دیسک اول (دیسک درست) را انتخاب می‌کند.

این مورد در نتیجه‌ی فرآیند ثبات روشناختی است.

سیستم بینایی صحنه‌ها را نرمال‌سازی می‌کند به‌گونه‌ای که ما فقط متوجه تغییرات روشناختی می‌شویم (نه مقدار مطلق آن).

Brightness Contrast



If you look at a point between the two circles, the small inner circle on the left will appear lighter than the small inner circle on the right, although they have the same brightness. It is relatively lighter than its surroundings.

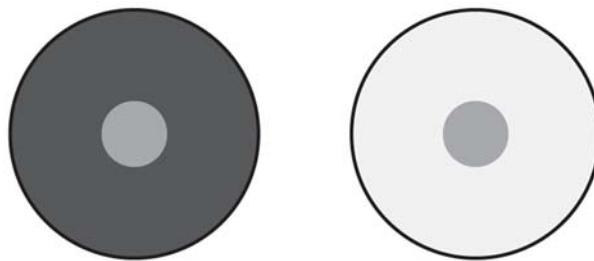
The visual system normalizes the scene. We see relative intensities.

سیستم بینایی انسان

نرمال‌سازی بینایی (کنتراست روشنایی)

VISION NORMALIZATION (BRIGHTNESS CONTRAST)

هر چند هر دو دیسک میانی دارای روشنایی یکسان هستند، اما دیسک داخل دایره‌ی تیره، روشن‌تر به نظر می‌رسد.



دلیل این امر حساسیت سیستم بینایی ما به شدت نورهای مرتبط با هم می‌باشد.

سیستم بینایی صحنه‌ها را نرمال‌سازی می‌کند به‌گونه‌ای که ما فقط متوجه شدت نورهای نسبی می‌شویم (نه مقدار مطلق آن).

شبکه‌ی گراسبرگ

۳

مدل
غیرخطی
پایه

مدل غیرخطی پایه

BASIC NONLINEAR MODEL

در ادامه:

ساختارهایی از شبکه‌های عصبی که با پدیده‌های فیزیکی تشریح شده در مورد سیستم بینایی انسان سازگاری دارند، را بررسی می‌کنیم.

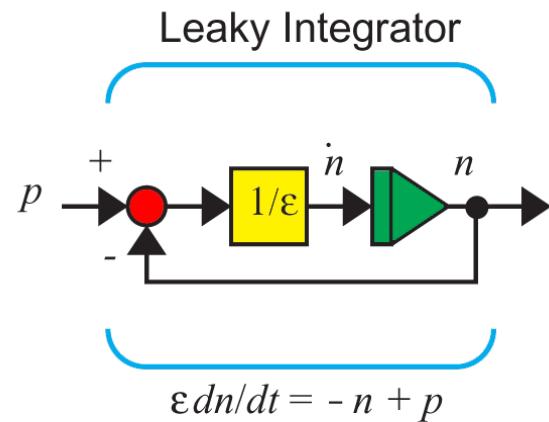
برای آشنایی با شبکه‌ی گراسبرگ، ابتدا باید برخی ساختارهای سازنده‌ی این شبکه را بررسی کنیم.

Leaky Integrator



(Building block for basic nonlinear model.)

$$\varepsilon \frac{dn(t)}{dt} = -n(t) + p(t)$$



مدل غیرخطی پایه

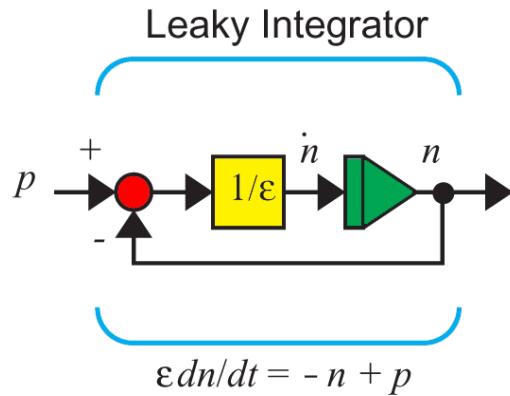
انتگرال‌گیری نشتشی دار

LEAKY INTEGRATOR

(Building block for basic nonlinear model.)

$$\varepsilon \frac{dn(t)}{dt} = -n(t) + p(t)$$

ε ثابت زمانی سیستم است.

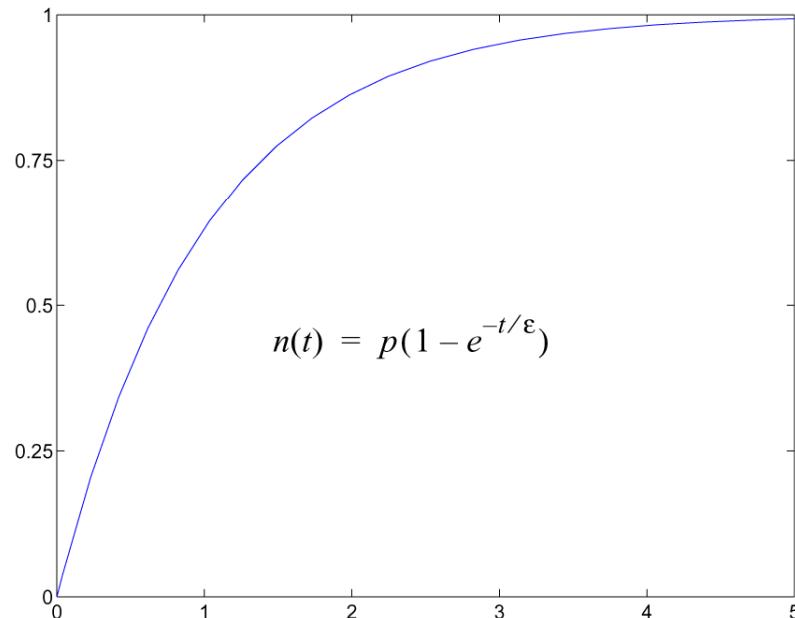


Leaky Integrator Response



$$n(t) = e^{-t/\varepsilon} n(0) + \frac{1}{\varepsilon} \int_0^t e^{-(t-\tau)/\varepsilon} p(\tau) d\tau$$

For a constant input and zero initial conditions:



مدل غیرخطی پایه

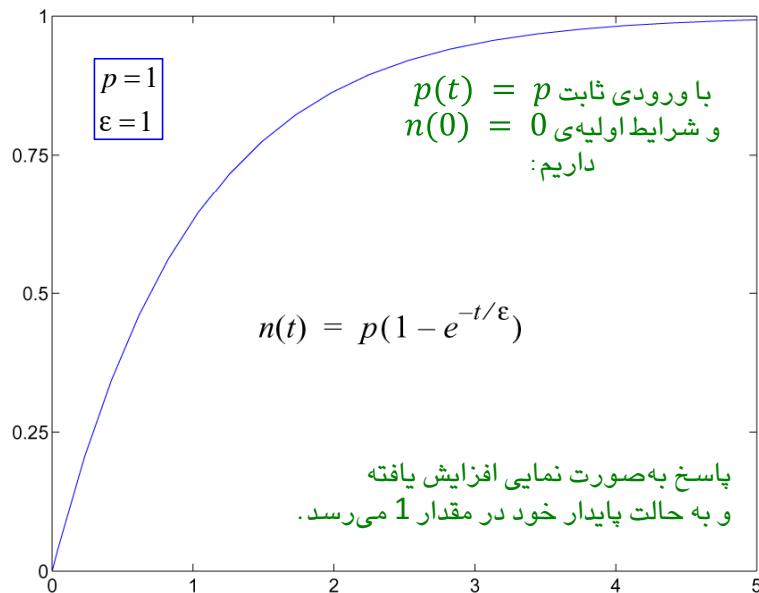
پاسخ انتگرال‌گیری نشتی دار

LEAKY INTEGRATOR RESPONSE

$$n(t) = e^{-t/\varepsilon} n(0) + \frac{1}{\varepsilon} \int_0^t e^{-(t-\tau)/\varepsilon} p(\tau) d\tau$$

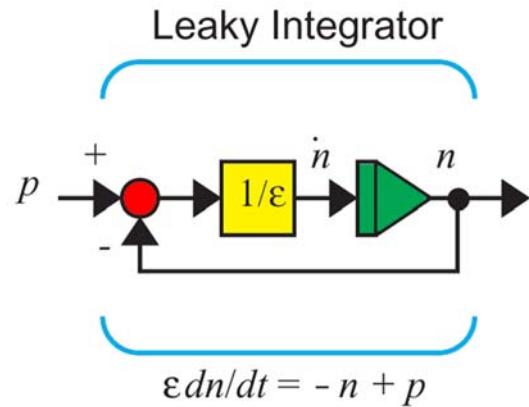
پاسخ انتگرال‌گیر نشتی دار به ورودی دلخواه $p(t)$

For a constant input and zero initial conditions:



مدل غیرخطی پایه

خصوصیات انتگرال‌گیری نشتشی دار

LEAKY INTEGRATOR

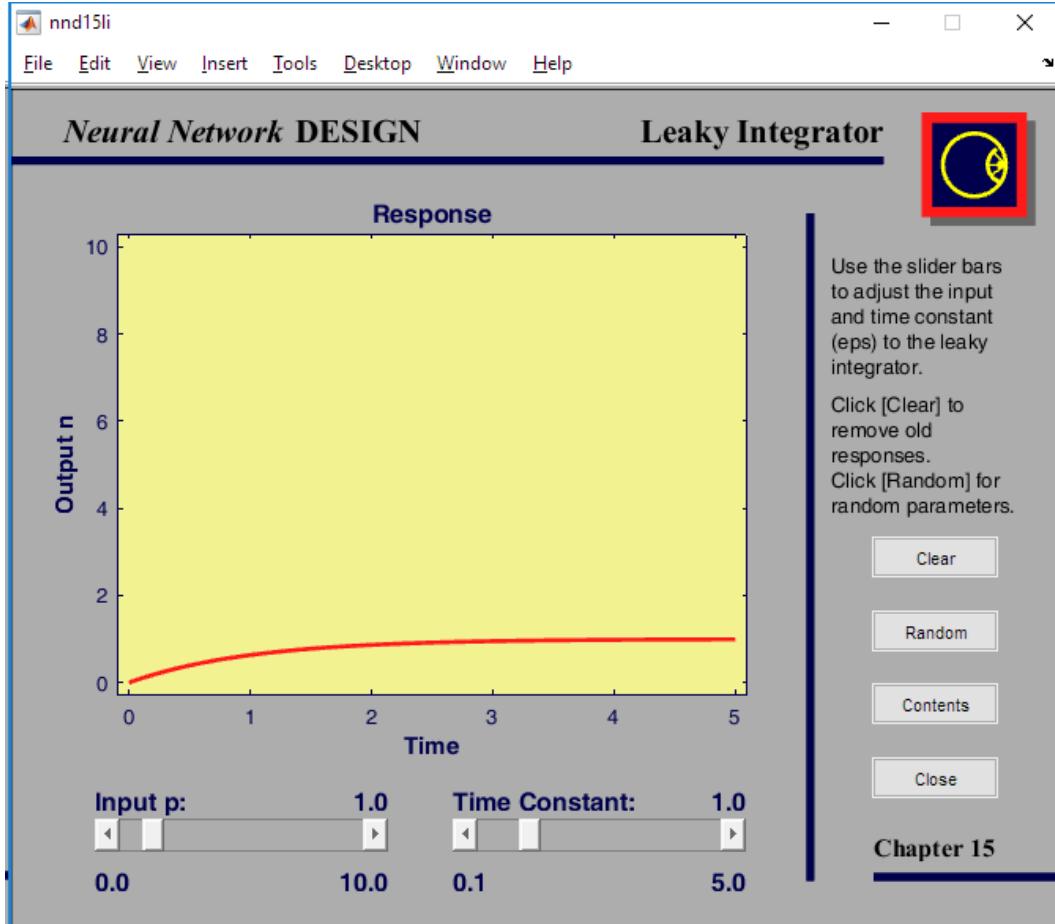
چون معادله‌ی پایه‌ی سیستم، خطی است،

در صورتی که ورودی p مقیاس شود، آن‌گاه خروجی n نیز به همان میزان مقیاس می‌شود.

سرعت پاسخ با توجه به ε (ثابت زمانی سیستم) مشخص می‌شود:

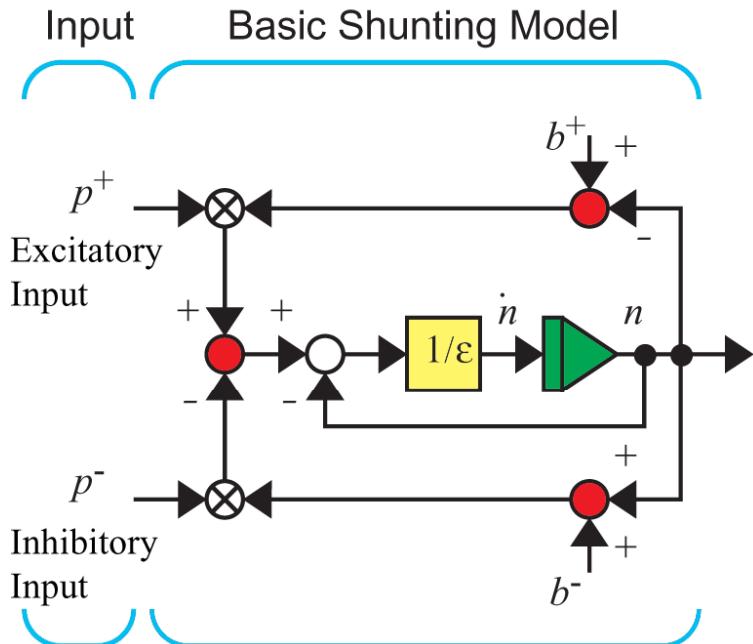
زمانی که ε کاهش می‌یابد، پاسخ سریع‌تر می‌شود؛

زمانی که ε افزایش می‌یابد، پاسخ آهسته‌تر می‌شود.



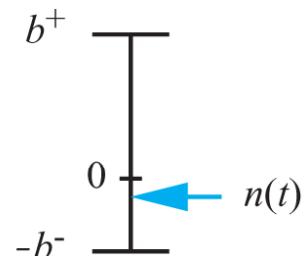
>> nnd15li

Shunting Model



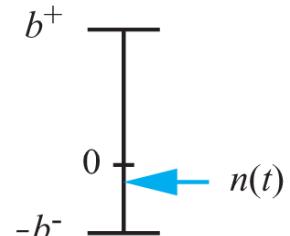
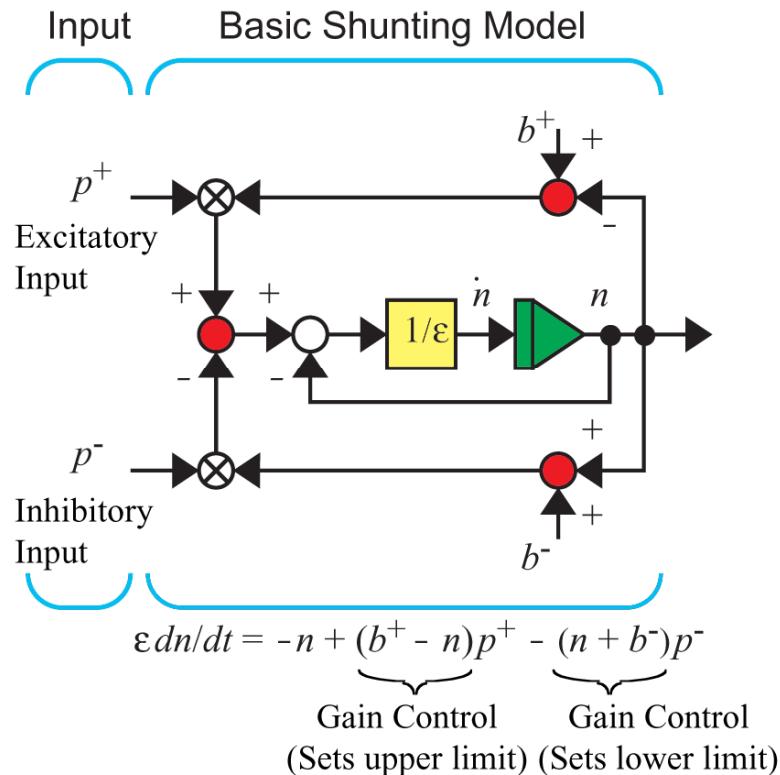
$$\varepsilon \frac{dn}{dt} = -n + (b^+ - n)p^+ - (n + b^-)p^-$$

Gain Control Gain Control
 (Sets upper limit) (Sets lower limit)



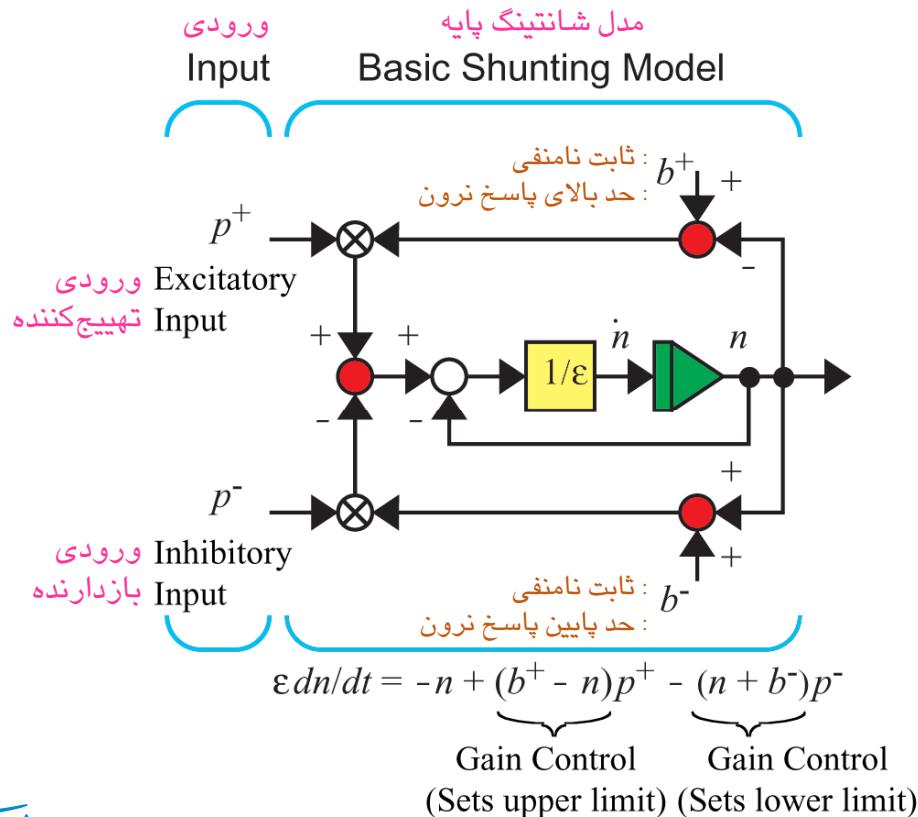
مدل شانتینگ

زیربنای شبکه‌های رقابتی گراسبرگ

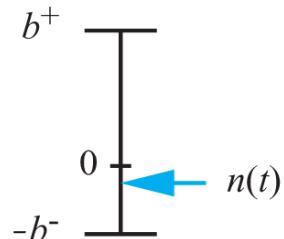
SHUNTING MODEL

مدل شانتینگ

SHUNTING MODEL



در صورتی که $n(0)$ بین b^+ و $-b^-$ باشد، آنگاه $n(t)$ بین این دو حد باقی می‌ماند.



مدل شانتینگ

معادله

SHUNTING MODEL

معادله دارای سه جمله در سمت راست است:

- * اگر علامت این سه جمله مثبت باشد $\Leftarrow n(t)$ بالا خواهد رفت.
- * اگر علامت این سه جمله منفی باشد $\Leftarrow n(t)$ پایین خواهد رفت.

$$\varepsilon \frac{dn(t)}{dt} = -n(t) + (b^+ - n(t))p^+ - (n(t) + b^-)p^-$$



جمله‌ی امحای خطی

جمله‌ی مهیا کننده‌ی کنترل بهره‌ی غیرخطی
 (اگر $n(t)$ کمتر از b^+ باشد، مقدار این جمله مثبت خواهد بود.)
 \Leftarrow فراهم شدن حد بالا برای $n(t)$

جمله‌ی مهیا کننده‌ی کنترل بهره‌ی غیرخطی

(اگر $n(t)$ بیشتر از $-b^-$ باشد، مقدار این جمله منفی خواهد بود.)
 \Leftarrow فراهم شدن حد پایین برای $n(t)$

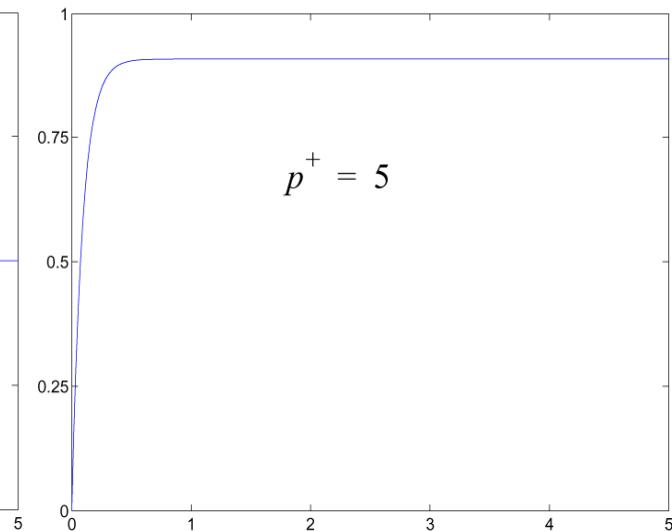
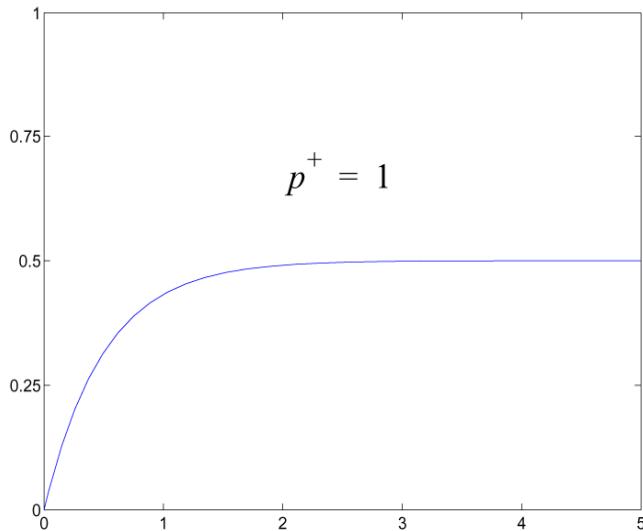
Shunting Model Response



$$\varepsilon \frac{dn(t)}{dt} = -n(t) + (b^+ - n(t))p^+ - (n(t) + b^-)p^-$$

$$b^+ = 1 \quad b^- = 0 \quad \varepsilon = 1 \quad p^- = 0$$

Upper limit will be 1, and lower limit will be 0.



مدل شانتینگ

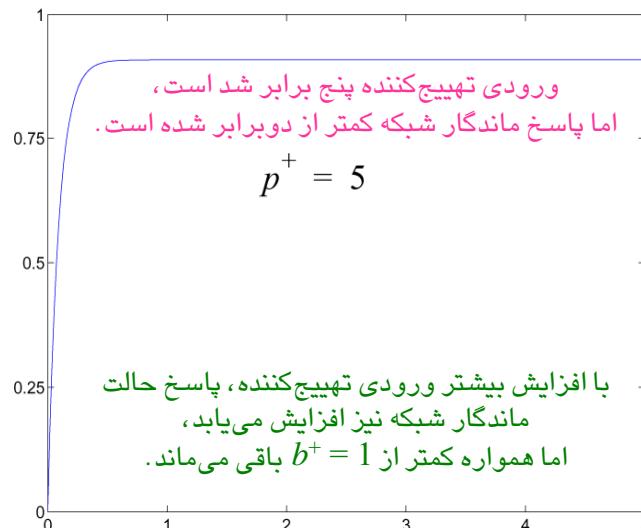
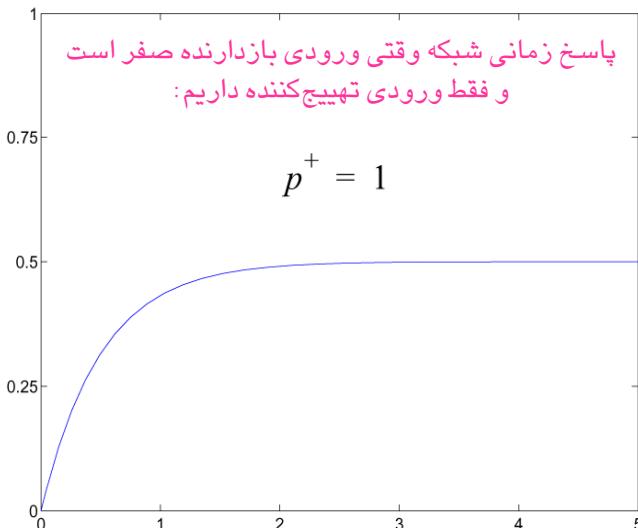
پاسخ مدل شانتینگ

SHUNTING MODEL RESPONSE

$$\epsilon \frac{dn(t)}{dt} = -n(t) + (b^+ - n(t))p^+ - (n(t) + b^-)p^-$$

$$b^+ = 1 \quad b^- = 0 \quad \epsilon = 1 \quad p^- = 0$$

Upper limit will be 1, and lower limit will be 0.



مدل شانتینگ

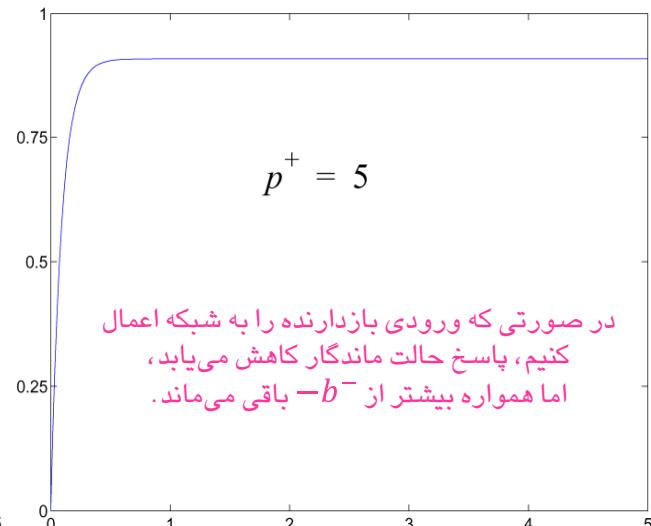
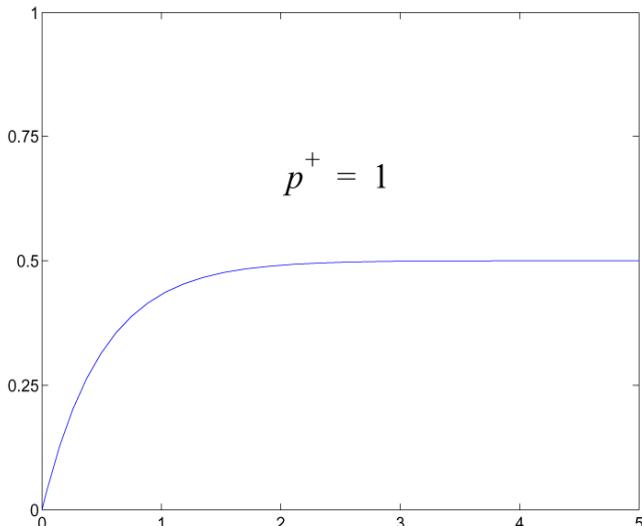
پاسخ مدل شانتینگ

SHUNTING MODEL RESPONSE

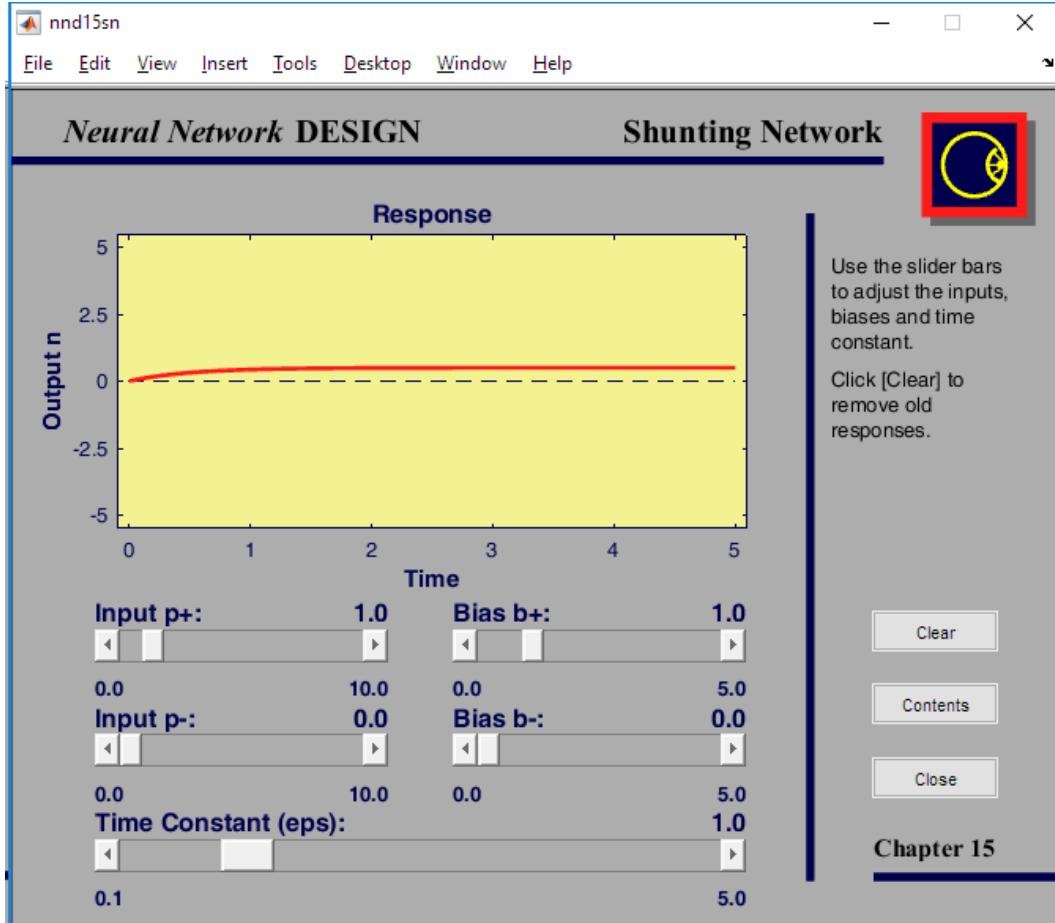
$$\varepsilon \frac{dn(t)}{dt} = -n(t) + (b^+ - n(t))p^+ - (n(t) + b^-)p^-$$

$$b^+ = 1 \quad b^- = 0 \quad \varepsilon = 1 \quad p^- = 0$$

Upper limit will be 1, and lower limit will be 0.



در صورتی که ورودی بازدارنده را به شبکه اعمال کنیم، پاسخ حالت ماندگار کاهش می‌یابد، اما همواره بیشتر از $-b^-$ باقی می‌ماند.



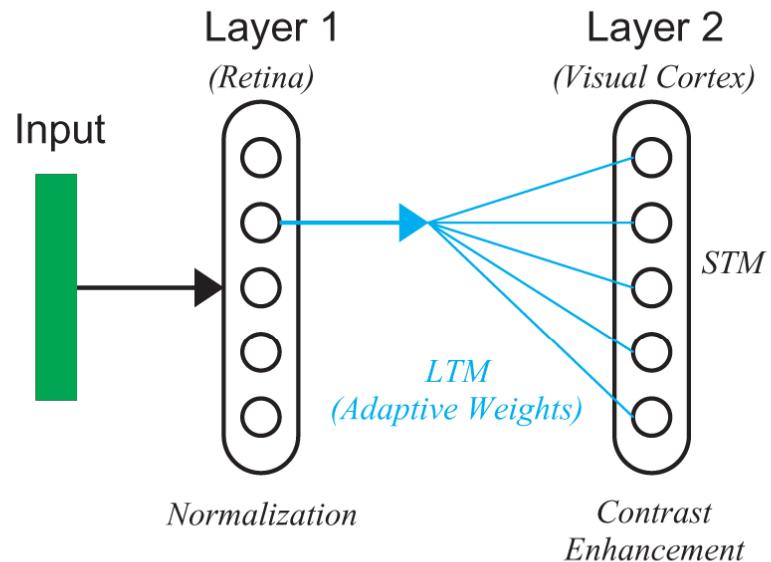
>> nnd15sn

شبکه‌ی گراسبرگ

۳۰

شبکه‌ی رقابتی دولایه

Grossberg Network

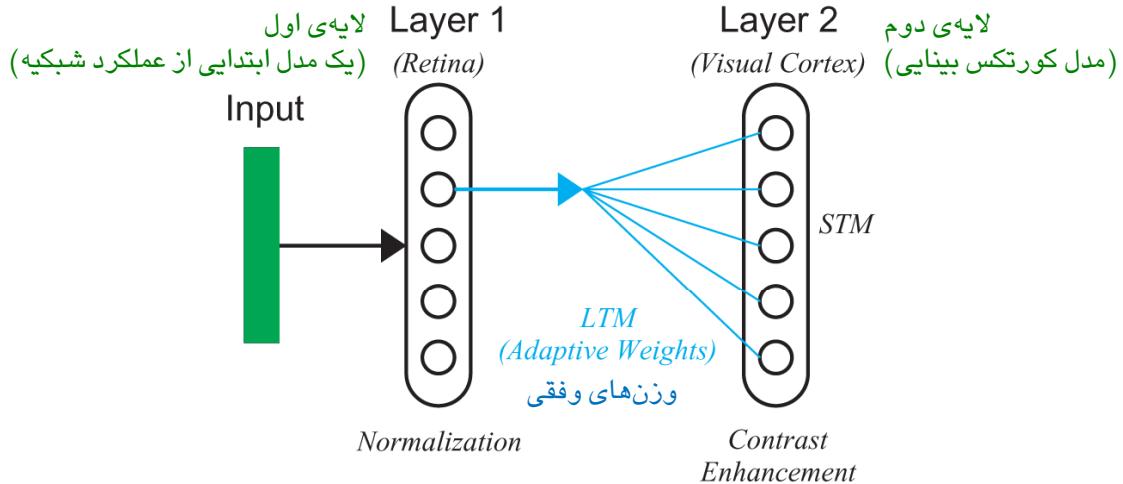


LTM - Long Term Memory (Network Weights)
STM - Short Term Memory (Network Outputs)

شبکه‌ی گراسبرگ

شبکه‌ی رقابتی گراسبرگ (با توجه به نوع عملکرد سیستم بینایی انسان)

GROSSBERG NETWORK

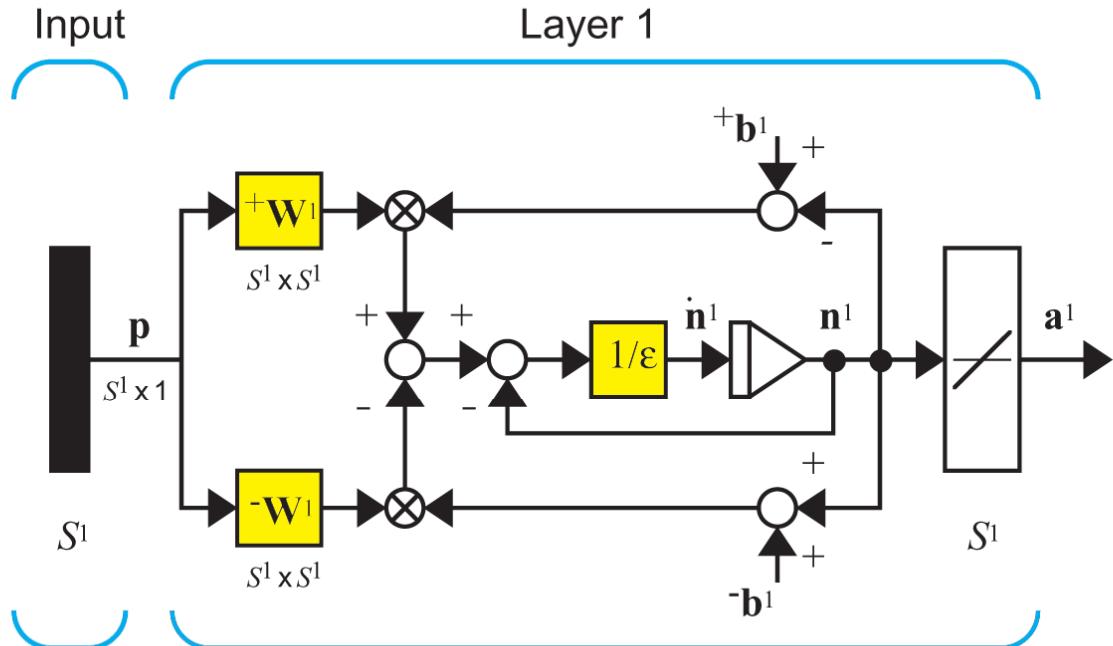


LTM - Long Term Memory (Network Weights)
STM - Short Term Memory (Network Outputs)

شبکه دارای دو مکانیسم STM و LTM است و اعمال ورقدهی، فیلتر کردن، نرمال‌سازی و ارتقای کنتراس است را انجام می‌دهد.

* این دو مدل قادر به پوشش کامل پیچیدگی‌های سیستم بینایی انسان نیستند، اما از برخی خصوصیات آن بهره‌مند می‌باشند.

Layer 1



$$\varepsilon d\mathbf{n}^1/dt = -\mathbf{n}^1 + ({}^+\mathbf{b}^1 - \mathbf{n}^1)[{}^+\mathbf{W}^1]\mathbf{p} - (\mathbf{n}^1 + {}^-\mathbf{b}^1)[{}^-\mathbf{W}^1]\mathbf{p}$$

شبکه‌ی گراسبرگ

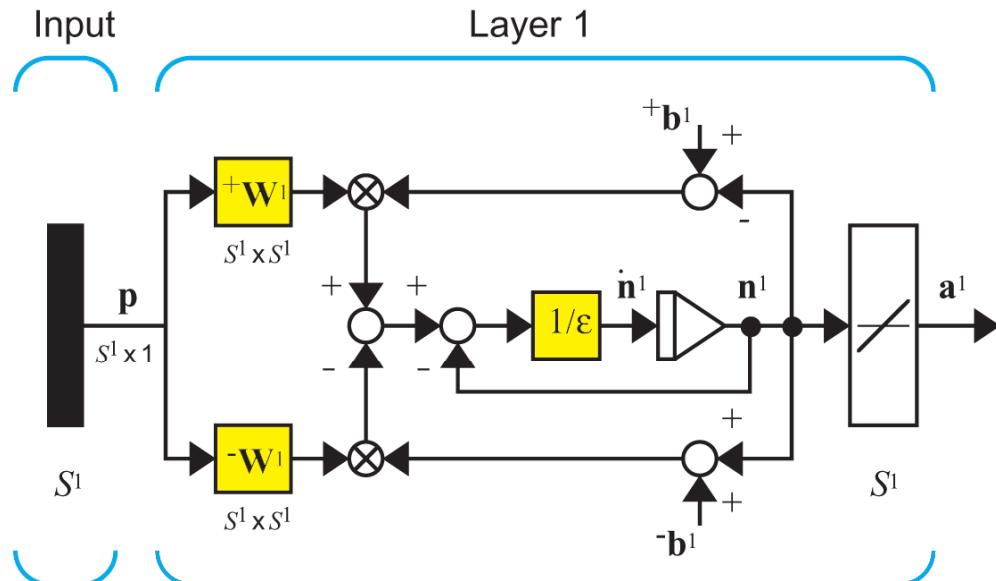
لایه‌ی ۱

LAYER 1

لایه‌ی ۱: ورودی خارجی را دریافت کرده و شدت الگوی ورودی را نرمال می‌کند.

در ساختار این لایه از مدل شانتینگ استفاده شده است.

در این مدل ورودی‌های تهییج‌کننده و بازدارنده از روی بردار ورودی p محاسبه می‌شوند.



$$\text{معادله‌ی عملکرد: } \frac{d\mathbf{n}^1}{dt} = -\mathbf{n}^1 + ({}^+ \mathbf{b}^1 - \mathbf{n}^1)[{}^+ \mathbf{W}^1] \mathbf{p} - (\mathbf{n}^1 + {}^- \mathbf{b}^1)[{}^- \mathbf{W}^1] \mathbf{p}$$

ثابت ۴ به‌گونه‌ای انتخاب می‌شود که عکس‌العمل نرون بسیار سریع‌تر از تغییر وزن‌های ورقی باشد.

Operation of Layer 1



$$\varepsilon \frac{d\mathbf{n}^1(t)}{dt} = -\mathbf{n}^1(t) + ({}^+\mathbf{b}^1 - \mathbf{n}^1(t)) [{}^+\mathbf{W}^1] \mathbf{p} - (\mathbf{n}^1(t) + {}^-\mathbf{b}^1) [{}^-\mathbf{W}^1] \mathbf{p}$$

$${}^-\mathbf{b}^1 = \mathbf{0}$$

$${}^+b_i^1 = {}^+b_i$$

Excitatory Input

$$[{}^+\mathbf{W}^1] \mathbf{p}$$

$${}^+\mathbf{W}^1 = \begin{bmatrix} 1 & 0 & \cdots & 0 \\ 0 & 1 & \cdots & 0 \\ \vdots & \vdots & & \vdots \\ 0 & 0 & \cdots & 1 \end{bmatrix}$$

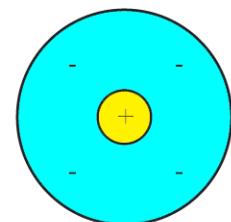
Inhibitory Input

$$[{}^-\mathbf{W}^1] \mathbf{p}$$

$${}^-\mathbf{W}^1 = \begin{bmatrix} 0 & 1 & \cdots & 1 \\ 1 & 0 & \cdots & 1 \\ \vdots & \vdots & & \vdots \\ 1 & 1 & \cdots & 0 \end{bmatrix}$$



On-Center/
Off-Surround
Connection
Pattern



Normalizes the input while maintaining relative intensities.

شبکه‌ی گراسبرگ

عملکرد لایه‌ی ۱

OPERATION OF LAYER 1

$$\varepsilon \frac{d\mathbf{n}^1(t)}{dt} = -\mathbf{n}^1(t) + (+\mathbf{b}^1 - \mathbf{n}^1(t)) [{}^+\mathbf{W}^1] \mathbf{p} - (\mathbf{n}^1(t) + {}^-\mathbf{b}^1) [{}^-\mathbf{W}^1] \mathbf{p}$$

$${}^-\mathbf{b}^1 = \mathbf{0}$$

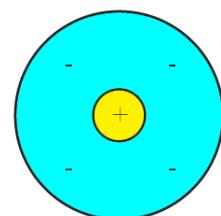
$${}^+b_i^1 = {}^+b^1$$

ورودی تهییج‌گر: ورودی تهییج‌گر نرون i -ام = i -امین عضو بردار ورودی است.

$${}^+\mathbf{W}^1 = \begin{bmatrix} 1 & 0 & \cdots & 0 \\ 0 & 1 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & 1 \end{bmatrix}$$

الگوی اتصال
مرکز-روشن/پیرامون-خاموش

On-Center/
Off-Surround
Connection
Pattern



ورودی بازدارنده: ورودی بازدارندهی نرون i -ام = مجموع همه‌ی اعضای بردار ورودی غیر از عضو i -ام

$${}^-\mathbf{W}^1 = \begin{bmatrix} 0 & 1 & \cdots & 1 \\ 1 & 0 & \cdots & 1 \\ \vdots & \vdots & \ddots & \vdots \\ 1 & 1 & \cdots & 0 \end{bmatrix}$$

لایه‌ی ۱، ورودی را نرمال‌سازی می‌کند در حالی که شدت‌های نسبی را نگه می‌دارد.

Normalizes the input while maintaining relative intensities.

و رودی تهییج‌گر نرون i -ام از عضوی از بردار ورودی به مرکزیت همان مکان (i) می‌آید، در حالی که ورودی بازدارنده از مکان‌های پیرامون i -ام می‌آید.

شبکه‌ی گراسبرگ

عملکرد لایه‌ی ۱

OPERATION OF LAYER 1

$$\varepsilon \frac{d\mathbf{n}^1(t)}{dt} = -\mathbf{n}^1(t) + ({}^+\mathbf{b}^1 - \mathbf{n}^1(t)) [{}^+\mathbf{W}^1] \mathbf{p} - (\mathbf{n}^1(t) + {}^-\mathbf{b}^1) [{}^-\mathbf{W}^1] \mathbf{p}$$

$${}^-\mathbf{b}^1 = \mathbf{0}$$

$${}^+b_i^1 = {}^+b^1$$

برای سادگی، بایاس بازدارنده ($-b^-$) را برابر با صفر قرار می‌دهیم.
 کران پایین مدل شانتینگ، صفر می‌شود.

برای سادگی، بایاس تهییج‌گر را برای همه‌ی نرون‌ها مساوی هم قرار می‌دهیم: $(\forall i \quad {}^+b_i^1 = {}^+b^1)$
 کران بالای همه‌ی نرون‌ها یکسان می‌شود.

Analysis of Normalization



Neuron i response:

$$\epsilon \frac{dn_i^1(t)}{dt} = -n_i^1(t) + ({}^+b^1 - n_i^1(t))p_i - n_i^1(t) \sum_{j \neq i} p_j$$

At steady state:

$$0 = -n_i^1 + ({}^+b^1 - n_i^1)p_i - n_i^1 \sum_{j \neq i} p_j \quad \rightarrow \quad n_i^1 = \frac{{}^+b^1 p_i}{1 + \sum_{j=1}^{S^1} p_j}$$

Define relative intensity:

$$\bar{p}_i = \frac{p_i}{P} \quad \text{where} \quad P = \sum_{j=1}^{S^1} p_j$$

Steady state neuron activity:

$$n_i^1 = \left(\frac{{}^+b^1 P}{1 + P} \right) \bar{p}_i$$

Total activity: $\sum_{j=1}^{S^1} n_j^1 = \sum_{j=1}^{S^1} \left(\frac{{}^+b^1 P}{1 + P} \right) \bar{p}_j = \left(\frac{{}^+b^1 P}{1 + P} \right) \leq {}^+b^1$

شبکه‌ی گراسبرگ

عملکرد لایه‌ی ۱: تحلیل نرمال‌سازی

ANALYSIS OF NORMALIZATION

Neuron i response:

پاسخ نرون در لایه‌ی ۱:

$$\varepsilon \frac{dn_i^1(t)}{dt} = -n_i^1(t) + (+b^1 - n_i^1(t))p_i - n_i^1(t) \sum_{j \neq i} p_j$$

At steady state:

در حالت ماندگار مشتق صفر است:

$$0 = -n_i^1 + (+b^1 - n_i^1)p_i - n_i^1 \sum_{j \neq i} p_j \quad \rightarrow \quad n_i^1 = \frac{+b^1 p_i}{1 + \sum_{j=1}^{S^1} p_j}$$

Define relative intensity:

مفهوم شدت نسبی ورودی i را به صورت زیر تعریف می‌کنیم:

$$\bar{p}_i = \frac{p_i}{P} \quad \text{where} \quad P = \sum_{j=1}^{S^1} p_j$$

Steady state neuron activity:

در این صورت، فعالیت نرون در حالت ماندگار می‌شود:

$$n_i^1 = \left(\frac{+b^1 P}{1 + P} \right) \bar{p}_i \quad \text{Total activity: } \sum_{j=1}^{S^1} n_j^1 = \sum_{j=1}^{S^1} \left(\frac{+b^1 P}{1 + P} \right) \bar{p}_j = \left(\frac{+b^1 P}{1 + P} \right) \leq +b^1$$

پس n_i^1 متناسب خواهد بود با شدت نسبی \bar{p}_i و از اندازه‌ی ورودی کلی P مستقل است.

شبکه‌ی گراسبرگ

عملکرد لایه‌ی ۱: تحلیل نرمال‌سازی

ANALYSIS OF NORMALIZATION

$$n_i^1 = \left(\frac{+b^1 P}{1 + P} \right) \bar{p}_i \quad \text{Total activity: } \sum_{j=1}^{S^1} n_j^1 = \sum_{j=1}^{S^1} \left(\frac{+b^1 P}{1 + P} \right) \bar{p}_j = \left(\frac{+b^1 P}{1 + P} \right) \leq +b^1$$

محدوده‌ی فعالیت نرون کران دار است:

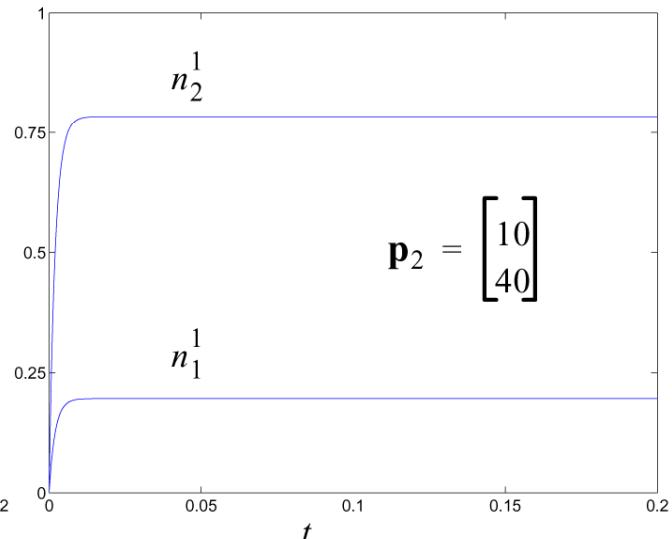
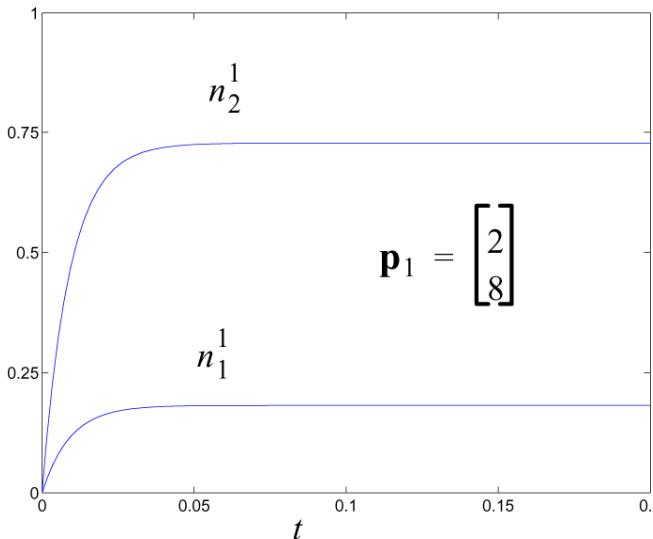
- بردار ورودی نرمال شده است، پس میزان فعالیت کل کمتر از $+b^1$ خواهد بود.
- این در حالی است که شدت‌های نسبی هر یک از اعضای بردار ورودی برقرار شده است.
- \Leftarrow خروجی‌های لایه‌ی ۱ (n_i^1)، شدت‌های نسبی ورودی (\bar{p}_i) را علاوه بر نوسان‌های لحظه‌ای فعالیت ورودی **p** کد می‌کند.
- این موضوع، نتیجه‌ی الگوی اتصال «مرکز-روشن/پیرامون-خاموش» ورودی‌ها و کنترل بهره‌ی غیرخطی مدل شانتینگ است.
- لایه‌ی ۱ شبکه‌ی گراسبرگ، نوعی شبیه‌سازی از خصوصیات «ثبات روشنایی» و «کنتراست روشنایی» از سیستم بینایی انسان است:
- شبکیه، به شدت نسبی تصویر، علاوه بر شدت مطلق آن حساس می‌باشد.
- علاوه بر آن، آزمایش‌ها نشان می‌دهد که الگوی اتصال «مرکز-روشن/پیرامون-خاموش» یک ویژگی خاص از نواحی دریافت‌گر سلول‌های لنفاوی شبکیه است که دریافت‌گرهای نوری یک سلول را تغذیه می‌کند.

Layer 1 Example



$$(0.1) \frac{dn_1^1(t)}{dt} = -n_1^1(t) + (1 - n_1^1(t))p_1 - n_1^1(t)p_2$$

$$(0.1) \frac{dn_2^1(t)}{dt} = -n_2^1(t) + (1 - n_2^1(t))p_2 - n_2^1(t)p_1$$



شبکه‌ی گراسبرگ

عملکرد لایه‌ی ۱ : مثال

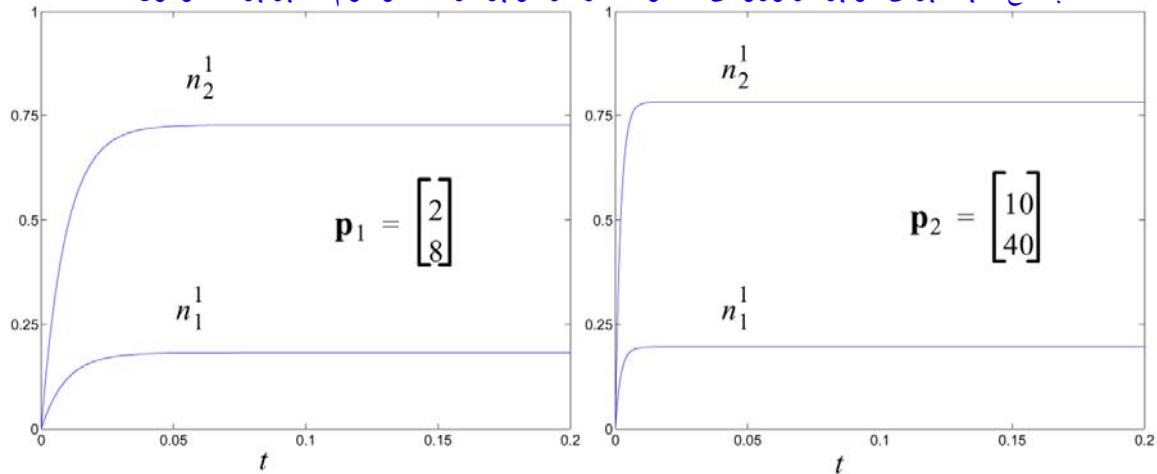
LAYER 1 EXAMPLE

یک لایه با دو نرون با $\epsilon = 0.1$ و $b^1 = 1$ در نظر می‌گیریم:

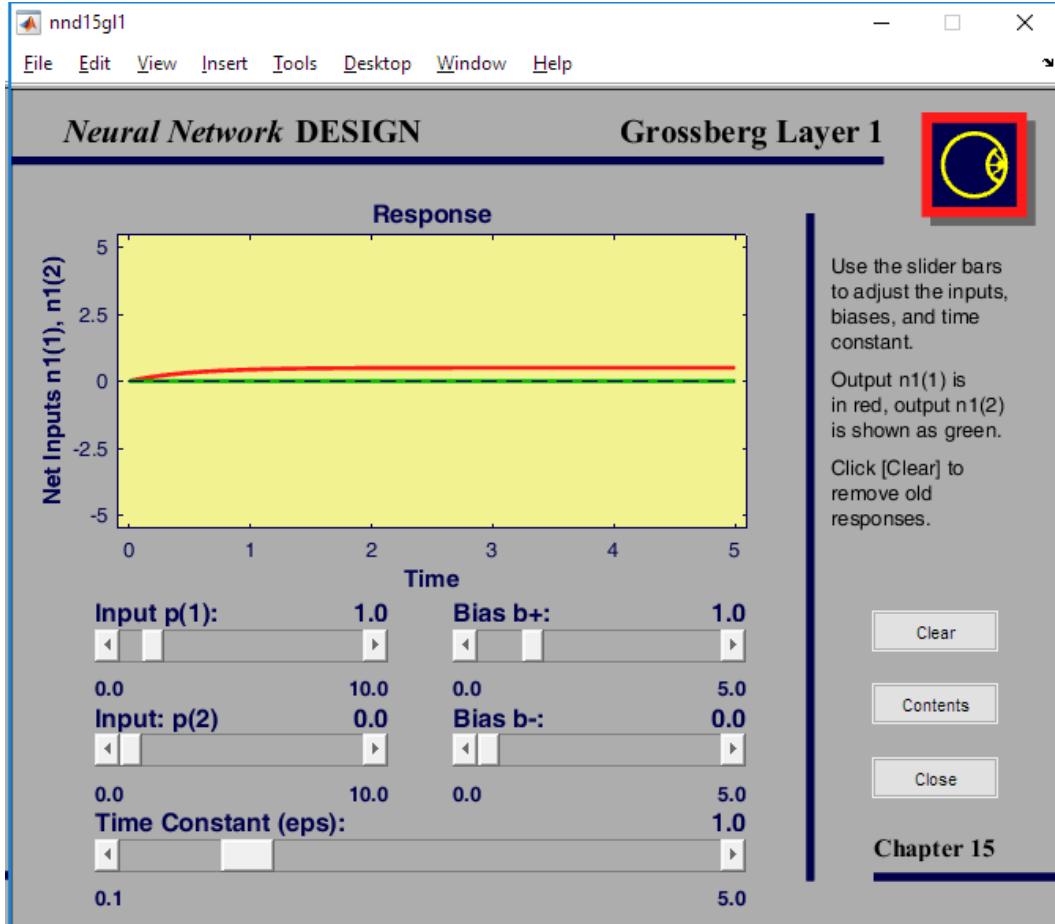
$$(0.1) \frac{dn_1^1(t)}{dt} = -n_1^1(t) + (1 - n_1^1(t))p_1 - n_1^1(t)p_2$$

$$(0.1) \frac{dn_2^1(t)}{dt} = -n_2^1(t) + (1 - n_2^1(t))p_2 - n_2^1(t)p_1$$

پاسخ شبکه برای دو بردار ورودی متفاوت: در هر دو بردار، عضو دوم، ۴ برابر عضو اول است:



← پاسخ شبکه، ایجاد کننده‌ی شدت نسبی ورودی‌هاست؛ پاسخ کل $n_1^1(t) + n_2^1(t)$ همواره کمتر از ۱ است.



>> nnd15gl1

Characteristics of Layer 1



- The network is sensitive to relative intensities of the input pattern, rather than absolute intensities.
- The output of Layer 1 is a normalized version of the input pattern.
- The on-center/off-surround connection pattern and the nonlinear gain control of the shunting model produce the normalization effect.
- The operation of Layer 1 explains the brightness constancy and brightness contrast characteristics of the human visual system.

شبکه‌ی گراسبرگ

مشخصه‌های لایه ۱

CHARACTERISTICS OF LAYER 1

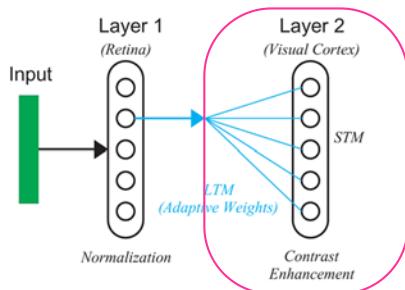
- شبکه به شدت‌های نسبی الگوی ورودی حساس است، علاوه بر شدت‌های مطلق.
- خروجی لایه ۱ یک نسخه‌ی نرمال شده از الگوی ورودی است.
- الگوی اتصال مرکز-روشن / پیرامون-خاموش و بهره‌ی کنترل غیرخطی مدل شانتینگ، اثر نرمال‌سازی را ایجاد می‌کند.
- عملکرد لایه ۱ مشخصه‌های ثبات روشنایی و کنتراست روشنایی سیستم بینایی انسان را توضیح می‌دهد.
- The network is sensitive to relative intensities of the input pattern, rather than absolute intensities.
- The output of Layer 1 is a normalized version of the input pattern.
- The on-center/off-surround connection pattern and the nonlinear gain control of the shunting model produce the normalization effect.
- The operation of Layer 1 explains the brightness constancy and brightness contrast characteristics of the human visual system.

شبکه‌ی گراسبرگ

لایه‌ی ۲

LAYER 2

لایه‌ی ۲ شبکه‌ی گراسبرگ: یک لایه از نرون‌های Instar پیوسته-زمان است و چند کارکرد مختلف را پیاده‌سازی می‌کند:



۱. مشابه لایه‌ی ۱، کل فعالیت لایه، نرمال‌سازی می‌شود.

۲. الگوهای مربوط به خود را ارتقای کنتراست می‌دهد
⇐ نرونی که بیشترین ورودی را دریافت می‌کند، بر پاسخ مسلط است.

۳. این لایه به عنوان یک حافظه‌ی کوتاه‌مدت STM عمل می‌کند و الگوهای ارتقای کنتراست یافته را نخیره می‌کند.

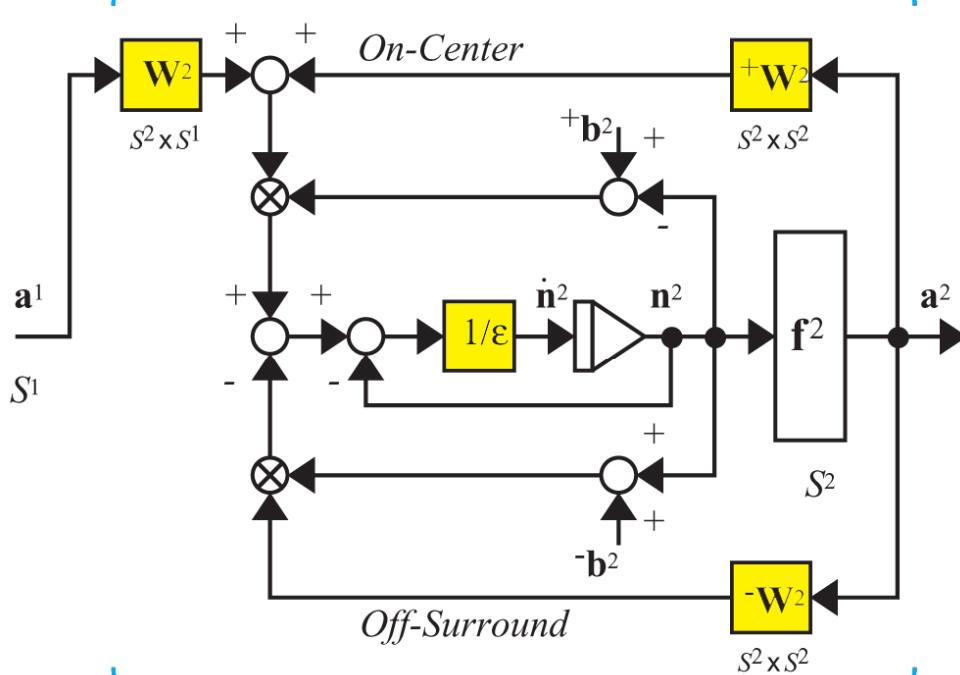
تفاوت اصلی لایه‌ی ۲ با لایه‌ی ۱: لایه‌ی ۲ از یک اتصال **فیدبک** استفاده می‌کند:
این فیدبک:

- ۱) به شبکه اجازه‌ی **ذخیره‌سازی یک الگو** را می‌دهد (حتی در صورت حذف شدن ورودی).
- ۲) **رقابتی** را به انجام می‌رساند که منجر به ارتقای کنتراست می‌شود.

Layer 2



Layer 2



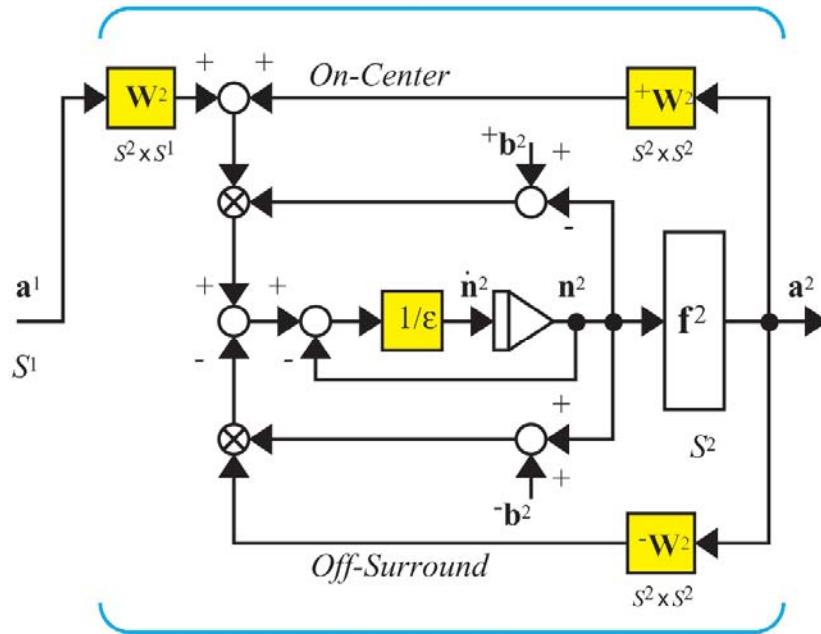
$$\begin{aligned} \varepsilon d\mathbf{n}^2/dt = & -\mathbf{n}^2 + (^+\mathbf{b}^2 - \mathbf{n}^2) \{ (^+\mathbf{W}^2) \mathbf{f}^2(\mathbf{n}^2) + \mathbf{W}^2 \mathbf{a}^1 \} \\ & - (\mathbf{n}^2 + ^-\mathbf{b}^2) [^-\mathbf{W}^2] \mathbf{f}^2(\mathbf{n}^2) \end{aligned}$$

شبکه‌ی گراسبرگ

لایه‌ی ۲

Layer 2

Layer 2



$$\begin{aligned} \varepsilon d\mathbf{n}^2/dt = & -\mathbf{n}^2 + (+\mathbf{b}^2 - \mathbf{n}^2) \{ [+\mathbf{W}^2] \mathbf{f}^2(\mathbf{n}^2) + \mathbf{W}^2 \mathbf{a}^1 \} \\ & - (\mathbf{n}^2 + -\mathbf{b}^2) [-\mathbf{W}^2] \mathbf{f}^2(\mathbf{n}^2) \end{aligned}$$

مدل شانتینگ پایه‌ی لایه‌ی دوم را تشکیل می‌دهد.

Layer 2 Operation



$$\begin{aligned} \varepsilon \frac{d\mathbf{n}^2(t)}{dt} = & -\mathbf{n}^2(t) + (^+\mathbf{b}^2 - \mathbf{n}^2(t)) \{ [^+\mathbf{W}^2] \mathbf{f}^2(\mathbf{n}^2(t)) + \mathbf{W}^2 \mathbf{a}^1 \} \\ & - (\mathbf{n}^2(t) + ^-\mathbf{b}^2) [^-\mathbf{W}^2] \mathbf{f}^2(\mathbf{n}^2(t)) \end{aligned}$$

Excitatory Input:

$$\{ [^+\mathbf{W}^2] \mathbf{f}^2(\mathbf{n}^2(t)) + \mathbf{W}^2 \mathbf{a}^1 \}$$

$$^+\mathbf{W}^2 = ^+\mathbf{W}^1 \quad (\text{On-center connections})$$

$$\mathbf{W}^2 \quad (\text{Adaptive weights})$$

Inhibitory Input:

$$[^-\mathbf{W}^2] \mathbf{f}^2(\mathbf{n}^2(t))$$

$$^-\mathbf{W}^2 = ^-\mathbf{W}^1 \quad (\text{Off-surround connections})$$

شبکه‌ی گراسبرگ

عملکرد لایه‌ی ۲

OPERATION OF LAYER 2

$$\varepsilon \frac{d\mathbf{n}^2(t)}{dt} = -\mathbf{n}^2(t) + (^+\mathbf{b}^2 - \mathbf{n}^2(t)) \{ [^+\mathbf{W}^2] \mathbf{f}^2(\mathbf{n}^2(t)) + \mathbf{W}^2 \mathbf{a}^1 \} \\ - (\mathbf{n}^2(t) + ^-\mathbf{b}^2) [^-\mathbf{W}^2] \mathbf{f}^2(\mathbf{n}^2(t))$$

Excitatory Input: ورودی تهییج‌گر:

$$\{ [^+\mathbf{W}^2] \mathbf{f}^2(\mathbf{n}^2(t)) + \mathbf{W}^2 \mathbf{a}^1 \}$$

: ایجاد اتصالات فیدبک مرکز-روشن $^+\mathbf{W}^2 = ^+\mathbf{W}^1$ (On-center connections)

: وزن‌های وفقی (معادل با وزن‌های شبکه‌ی کوهونن) \mathbf{W}^2 (Adaptive weights)

Inhibitory Input: ورودی بازدارنده:

$$[^-\mathbf{W}^2] \mathbf{f}^2(\mathbf{n}^2(t))$$

: ایجاد اتصالات فیدبک پیرامون-خاموش $^-\mathbf{W}^2 = ^-\mathbf{W}^1$ (Off-surround connections)

شبکه‌ی گراسبرگ

عملکرد لایه‌ی ۲

OPERATION OF LAYER 2

ورودی‌های لایه‌ی دوم از ضرب داخلی میان الگوهای اولیه (سطرهای ماتریس وزن² W^2) و خروجی لایه‌ی اول (الگوهای ورودی نرمال شده) حاصل می‌شود.

بزرگترین ضرب داخلی، متناظر با نزدیکترین الگوی اولیه با الگوی ورودی خواهد بود.

سپس لایه‌ی دوم یک رقابت میان نرون‌ها برگزار می‌کند که منجر به ارتقای کنtras است الگوی خروجی می‌شود
 ⇐ برجسته شدن خروجی‌های بزرگ و محو شدن الگوهای کوچک

* این نوع ارتقای کنtras عموماً نسبت به رقابت «برنده همه را می‌خورد» در شبکه‌های همینگ و کوهونن ملايمتر است.

در آنها خروجی همه‌ی نرون‌های بازنده صفر است و فقط خروجی نرون برنده برابر با ۱ است.

در شبکه‌ی گراسبرگ رقابت منجر به برجسته شدن مقادیر بزرگ‌تر و محو شدن مقادیر کوچک‌تر می‌شود ولی خروجی مقادیر کوچک‌تر لزوماً برابر با صفر نیست.

مقدار ارتقای کنtras در لایه‌ی دوم با توجه بهتابع انتقال² f^2 تعیین می‌شود.

Layer 2 Example



$$\varepsilon = 0.1 \quad {}^+\mathbf{b}^2 = \begin{bmatrix} 1 \\ 1 \end{bmatrix} \quad {}^-\mathbf{b}^2 = \begin{bmatrix} 0 \\ 0 \end{bmatrix} \quad f^2(n) = \frac{10(n)^2}{1 + (n)^2} \quad \mathbf{W}^2 = \begin{bmatrix} ({}_1\mathbf{w}^2)^T \\ ({}_2\mathbf{w}^2)^T \end{bmatrix} = \begin{bmatrix} 0.9 & 0.45 \\ 0.45 & 0.9 \end{bmatrix}$$

Correlation between
prototype 1 and input.

$$(0.1) \frac{dn_1^2(t)}{dt} = -n_1^2(t) + (1 - n_1^2(t)) \overbrace{\left\{ f^2(n_1^2(t)) + ({}_1\mathbf{w}^2)^T \mathbf{a}^1 \right\}}^{\text{Correlation between prototype 1 and input.}} - n_1^2(t) f^2(n_2^2(t))$$

Correlation between
prototype 2 and input.

$$(0.1) \frac{dn_2^2(t)}{dt} = -n_2^2(t) + (1 - n_2^2(t)) \overbrace{\left\{ f^2(n_2^2(t)) + ({}_2\mathbf{w}^2)^T \mathbf{a}^1 \right\}}^{\text{Correlation between prototype 2 and input.}} - n_2^2(t) f^2(n_1^2(t)) .$$

شبکه‌ی گراسبرگ

عملکرد لایه‌ی ۲ : مثال

OPERATION OF LAYER 2

$$\varepsilon = 0.1 \quad {}^+ \mathbf{b}^2 = \begin{bmatrix} 1 \\ 1 \end{bmatrix} \quad {}^- \mathbf{b}^2 = \begin{bmatrix} 0 \\ 0 \end{bmatrix} \quad f^2(n) = \frac{10(n)^2}{1 + (n)^2} \quad \mathbf{W}^2 = \begin{bmatrix} ({}_1 \mathbf{w}^2)^T \\ ({}_2 \mathbf{w}^2)^T \end{bmatrix} = \begin{bmatrix} 0.9 & 0.45 \\ 0.45 & 0.9 \end{bmatrix}$$

Correlation between
prototype 1 and input.

$$(0.1) \frac{dn_1^2(t)}{dt} = -n_1^2(t) + (1 - n_1^2(t)) \left\{ \overbrace{f^2(n_1^2(t)) + ({}_1 \mathbf{w}^2)^T \mathbf{a}^1}^1 \right\} - n_1^2(t) f^2(n_2^2(t))$$

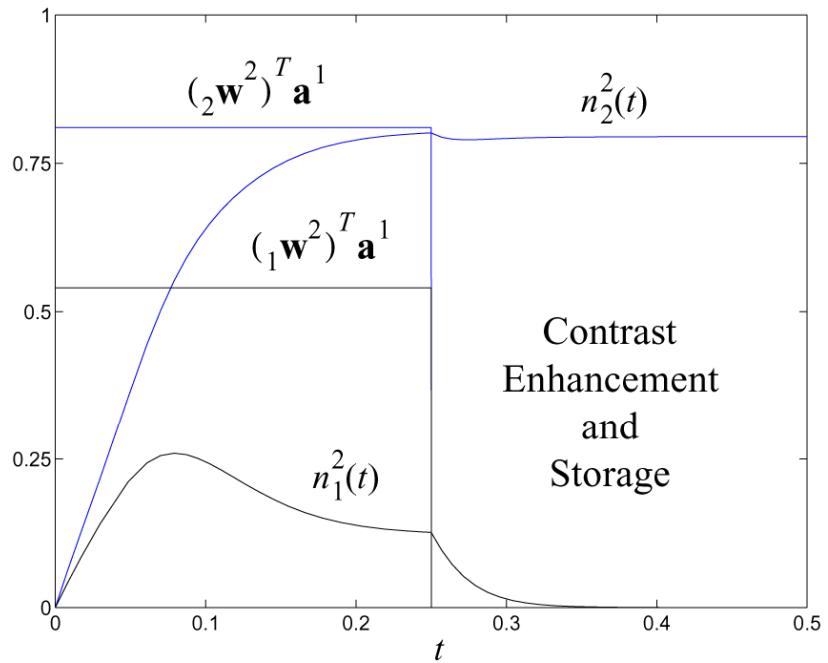
Correlation between
prototype 2 and input.

$$(0.1) \frac{dn_2^2(t)}{dt} = -n_2^2(t) + (1 - n_2^2(t)) \left\{ \overbrace{f^2(n_2^2(t)) + ({}_2 \mathbf{w}^2)^T \mathbf{a}^1}^1 \right\} - n_2^2(t) f^2(n_1^2(t)) .$$

Layer 2 Response



$$\mathbf{a}^1 = \begin{bmatrix} 0.2 \\ 0.8 \end{bmatrix}$$



Input to neuron 1:

$$(_1\mathbf{w}^2)^T \mathbf{a}^1 = [0.9 \ 0.45] \begin{bmatrix} 0.2 \\ 0.8 \end{bmatrix} = 0.54$$

Input to neuron 2:

$$(_2\mathbf{w}^2)^T \mathbf{a}^1 = [0.45 \ 0.9] \begin{bmatrix} 0.2 \\ 0.8 \end{bmatrix} = 0.81$$

شبکه‌ی گراسبرگ

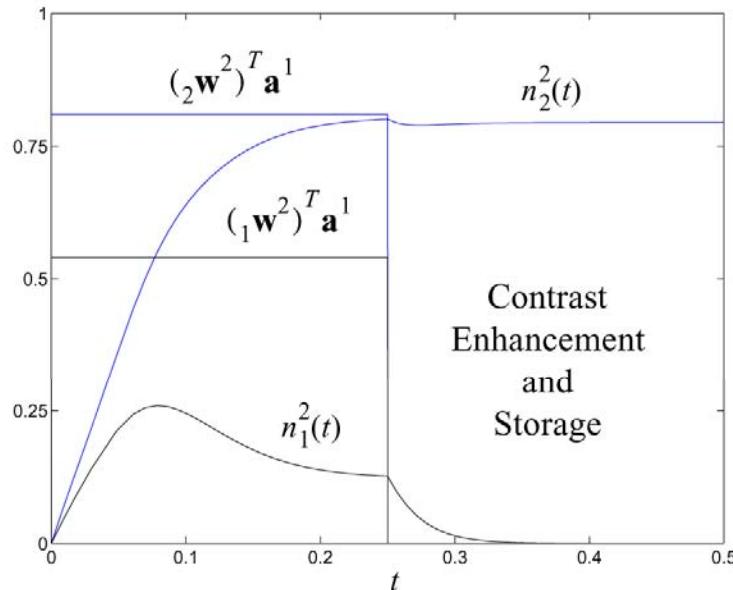
مثال: پاسخ لایه‌ی ۲

LAYER 2 RESPONSE

ورودی:

$$\mathbf{a}^1 = \begin{bmatrix} 0.2 \\ 0.8 \end{bmatrix}$$

نتیجه‌ی حالت ماندگار لایه‌ی ۱
به مدت ۰.۲۵ ثانیه به شبکه
اعمال شده است و سپس
حذف می‌شود.



Input to neuron 1:

$$(1\mathbf{w}^2)^T \mathbf{a}^1 = [0.9 \ 0.45] \begin{bmatrix} 0.2 \\ 0.8 \end{bmatrix} = 0.54$$

Input to neuron 2:

$$(2\mathbf{w}^2)^T \mathbf{a}^1 = [0.45 \ 0.9] \begin{bmatrix} 0.2 \\ 0.8 \end{bmatrix} = 0.81$$

* فیدبک غیر خطی شبکه را قادر به ذخیره‌سازی الگو می‌کند.

* اتصالات «مرکز-روشن/پیرامون-خاموش» باعث ارتقای کنتراست می‌شوند.

دو خصوصیت مهم
این پاسخ:

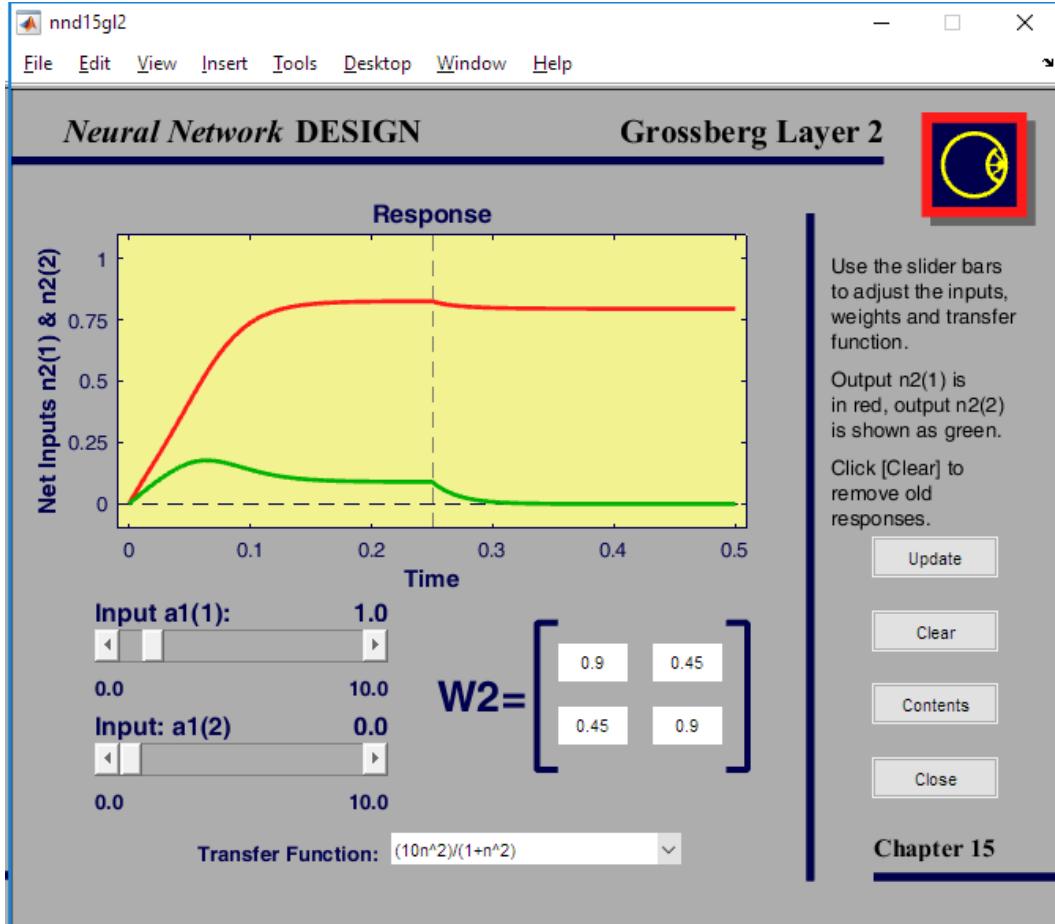
(۱)

حتی پیش از حذف
ورودی، نوعی ارتقای
کنتراست اتفاق می‌افتد.

(۲)

پس از اینکه ورودی برابر
با صفر قرار داده می‌شود،
شبکه میزان کنتراست را
ارتقا داده و الگو را ذخیره
می‌کند.

(به این رفتار شبکه، طین -
reverberation می‌گویند)



>> nnd15gl2

Characteristics of Layer 2



- As in the Hamming and Kohonen networks, the inputs to Layer 2 are the inner products between the prototype patterns (rows of the weight matrix \mathbf{W}^2) and the output of Layer 1 (normalized input pattern).
- The nonlinear feedback enables the network to store the output pattern (pattern remains after input is removed).
- The on-center/off-surround connection pattern causes contrast enhancement (large inputs are maintained, while small inputs are attenuated).

شبکه‌ی گراسبرگ

مشخصه‌های لایه ۲

CHARACTERISTICS OF LAYER 1

همانند شبکه‌های همینگ و کوهونن، ورودی‌های لایه‌ی ۲ ضرب‌های داخلی میان الگوهای پروتوتایپ (سطرهای ماتریس وزن \mathbf{W}^2) و خروجی لایه‌ی ۱ (الگوی ورودی نرمال شده است).

فیدبک غیرخطی شبکه را قادر می‌کند که الگوی خروجی را ذخیره کند (الگو پس از حذف شدن ورودی باقی می‌ماند).

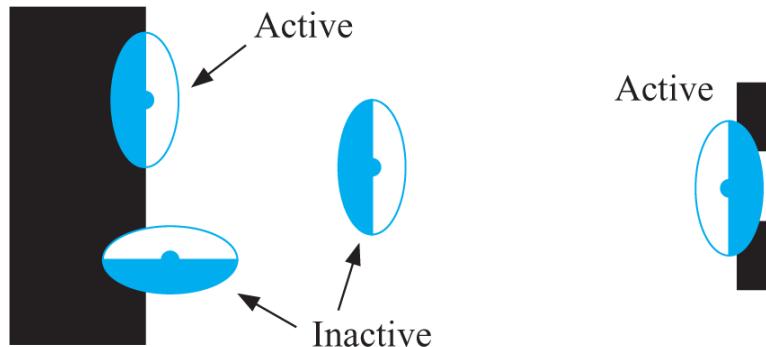
الگوی اتصالات «مرکز-روشن/پیرامون-خاموش» موجب ارتقای کنتراست می‌شود (ورودی‌های بزرگ حفظ می‌شوند، در حالی که ورودی‌های کوچک تضعیف می‌شوند).

- As in the Hamming and Kohonen networks, the inputs to Layer 2 are the inner products between the prototype patterns (rows of the weight matrix \mathbf{W}^2) and the output of Layer 1 (normalized input pattern).
- The nonlinear feedback enables the network to store the output pattern (pattern remains after input is removed).
- The on-center/off-surround connection pattern causes contrast enhancement (large inputs are maintained, while small inputs are attenuated).

Oriented Receptive Field



When an oriented receptive field is used, instead of an on-center/off-surround receptive field, the emergent segmentation problem can be understood.



شبکه‌ی گراسبرگ

میدان پذیرنده‌ی گرادار

ORIENTED RECEPTIVE FIELD

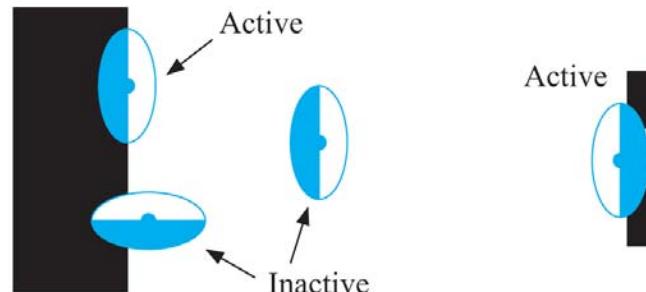
: Emergent Segmentation مسئله‌ی

از ساختار «میدان پذیرنده‌ی گرادار» برای پیاده‌سازی این مکانیسم استفاده شده است.

: اتصالات تهییج گر (on) در یک سمت اتصالات بازدارنده (off) در سمت دیگر:



When an oriented receptive field is used, instead of an on-center/off-surround receptive field, the emergent segmentation problem can be understood.



این مثال نشان می‌دهد که چرا ممکن است در ناحیه‌ای که لبه وجود ندارد، مایک لبه تشخیص دهیم:

زمانی که میدان بر یک لبه منطبق باشد، میدان متناظر فعال خواهد شد و زمانی که میدان منطبق بر یک لبه نباشد، نرون غیرفعال خواهد بود.

شبکه‌ی گراسبرگ

انتخاب تابع انتقال لایه‌ی دوم

CHOICE OF TRANSFER FUNCTION

رفتار لایه‌ی دوم شبکه‌ی گراسبرگ تا حد زیادی به تابع انتقال f^2 بستگی دارد.

Choice of Transfer Function



$f^2(n)$	Stored Pattern $\mathbf{n}^2(\infty)$	Comments
Linear		Perfect storage of any pattern, but amplifies noise.
Slower than Linear		Amplifies noise, reduces contrast.
Faster than Linear		Winner-take-all, suppresses noise, quantizes total activity.
Sigmoid		Suppresses noise, contrast enhances, not quantized.

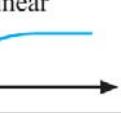
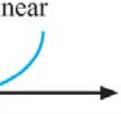
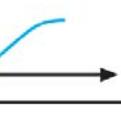
Figure illustrating the choice of transfer function for pattern storage. On the left, a graph shows the initial stored pattern $n^2_i(0)$ versus index i , characterized by high-frequency noise. The table below shows four different transfer functions ($f^2(n)$) and their resulting stored patterns $\mathbf{n}^2(\infty)$ and associated comments.

شبکه های گراسبرگ

انتخاب تابع انتقال لایه دوم

CHOICE OF TRANSFER FUNCTION

نحوه تأثیر انتخاب $f^2(n)$ بر روی پاسخ حالت ماندگار شبکه در صورت حذف ورودی
برای مثال فرض کنید یک ورودی برای یک مدت زمان کوتاه به شبکه اعمال شود \leftrightarrow خروجی مطابق شکل به حالت ماندگار می‌رسد.

$f^2(n)$	Stored Pattern $n^2(\infty)$	Comments
Linear		Perfect storage of any pattern, but amplifies noise.
Slower than Linear		Amplifies noise, reduces contrast.
Faster than Linear		Winner-take-all, suppresses noise, quantizes total activity.
Sigmoid		Suppresses noise, contrast enhances, not quantized.

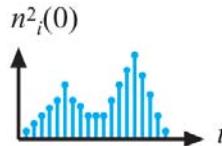
تابع انتقال خطی:
الگو به طور کامل ذخیره می‌شود،
نویز همراه با الگو تقویت و در کنار آن ذخیره می‌شود.

تابع انتقال آهسته‌تر از خطی:
پاسخ حالت ماندگار مستقل از شرایط آغازین؛ همه کنتراستها حذف و نویز تقویت می‌شود.

تابع انتقال سریع‌تر از خطی:
ایجاد رقابت «برنده همه را می‌خورد»
نرون‌های دارای بیشترین مقدار آغازین ذخیره شده و بقیه حذف می‌شوند
 \leftarrow حداقل شدن تاثیرات منفی نویز

تابع انتقال سیکمودیه: برای
سیکنال‌های کوچک: سریع‌تر از خطی؛
سیکنال‌های متوسط: تقریباً خطی؛
سیکنال‌های بزرگ: آهسته‌تر از خطی؛

هر نقطه نمایش‌گر یک نرون است:



شبکه‌ی گراسبرگ

انتخاب تابع انتقال لایه‌ی دوم: تابع سیگموئید

CHOICE OF TRANSFER FUNCTION

زمانی که از تابع انتقال سیگموئید به عنوان $f^2(n)$ استفاده می‌شود، کنتراست الگو ارتقا داده می‌شود:

مقادیر بزرگ‌تر تقویت شده و مقادیر کوچک‌تر محو می‌شوند.
 ⇐ خروجی‌هایی که کمتر از حد معینی هستند (آستانه‌ی اطفاء)، به سمت صفر محو می‌شوند.

⇐ خصوصیت حذف نویز در توابع انتقال سریع‌تر از خطی،
 با خصوصیت ذخیره‌سازی کامل در مورد توابع انتقال خطی، ادغام می‌شود.

Adaptive Weights



Hebb Rule with Decay

$$\frac{dw_{i,j}^2(t)}{dt} = \alpha \{-w_{i,j}^2(t) + n_i^2(t)n_j^1(t)\}$$

Instar Rule
(Gated Learning)

$$\frac{dw_{i,j}^2(t)}{dt} = \alpha n_i^2(t) \{-w_{i,j}^2(t) + n_j^1(t)\}$$

 Learn when
 $n_i^2(t)$ is active.

Vector Instar Rule

$$\frac{d[i\mathbf{w}^2(t)]}{dt} = \alpha n_i^2(t) \{-[i\mathbf{w}^2(t)] + \mathbf{n}^1(t)\}$$

شبکه‌ی گراسبرگ

وزن‌های وفقی

ADAPTIVE WEIGHTS

مانند شبکه‌های همینگ و کوهون،
الگوهای ذخیره شده‌ای که در
نزدیک‌ترین حالت نسبت به
الگوهای ورودی هستند،
بزرگ‌ترین خروجی لایه‌ی دوم را
تولید می‌کنند.

قانون یادگیری وزن‌های وفقی (\mathbf{W}^2)

Hebb Rule with Decay

$$\frac{dw_{i,j}^2(t)}{dt} = \alpha \{-w_{i,j}^2(t) + n_i^2(t)n_j^1(t)\}$$

passive decay

Jمله‌ی
Instar Rule
(Gated Learning)

گراسبرگ به این وزن‌های وفقی،
حافظه‌ی بلندمدت (LTM) می‌گوید:

زیرا سطرهای \mathbf{W}^2 بازنمایی کننده‌ی
الگوهای ذخیره شده‌ای است که شبکه
توانایی تشخیص آنها را دارد.

$\left\{ \begin{array}{l} \text{Learn when} \\ n_i^2(t) \text{ is active.} \end{array} \right.$

اغلب، غیر فعال کردن یادگیری (فراموشی) در صورت غیر فعال بودن $n_i^2(t)$ مفید است.

Vector Instar Rule

$$\frac{d[i\mathbf{w}^2(t)]}{dt} = \alpha n_i^2(t) \{-[i\mathbf{w}^2(t)] + \mathbf{n}^1(t)\}$$

طرف راست قاعده‌ی یادگیری در $n_i^2(t)$ ضرب شده است \Leftarrow یادگیری فقط در زمان غیر صفر بودن آن انجام می‌شود.
[پیاده‌سازی پیوسته-زمان قاعده‌ی یادگیری Instar]

Example



$$\frac{dw_{1,1}^2(t)}{dt} = n_1^2(t) \{-w_{1,1}^2(t) + n_1^1(t)\}$$

$$\frac{dw_{1,2}^2(t)}{dt} = n_1^2(t) \{-w_{1,2}^2(t) + n_2^1(t)\}$$

$$\frac{dw_{2,1}^2(t)}{dt} = n_2^2(t) \{-w_{2,1}^2(t) + n_1^1(t)\}$$

$$\frac{dw_{2,2}^2(t)}{dt} = n_2^2(t) \{-w_{2,2}^2(t) + n_2^1(t)\}$$

شبکه‌ی گراسبرگ

وزن‌های وفقی: مثال

ADAPTIVE WEIGHTS

یک شبکه‌ی گراسبرگ با دو نرون در هر لایه:

معادلات به روزرسانی وزن‌ها:

$$\frac{dw_{1,1}^2(t)}{dt} = n_1^2(t) \{-w_{1,1}^2(t) + n_1^1(t)\}$$

$$\frac{dw_{1,2}^2(t)}{dt} = n_1^2(t) \{-w_{1,2}^2(t) + n_2^1(t)\}$$

$$\frac{dw_{2,1}^2(t)}{dt} = n_2^2(t) \{-w_{2,1}^2(t) + n_1^1(t)\}$$

$$\frac{dw_{2,2}^2(t)}{dt} = n_2^2(t) \{-w_{2,2}^2(t) + n_2^1(t)\}$$

نرخ یادگیری $\alpha = 1$

Response of Adaptive Weights



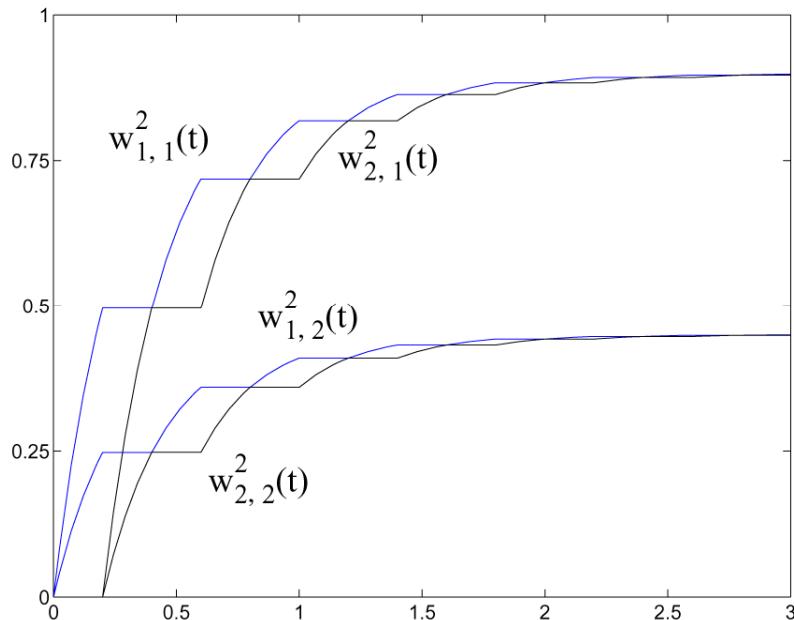
Two different input patterns are alternately presented to the network for periods of 0.2 seconds at a time.

For Pattern 1:

$$\mathbf{n}^1 = \begin{bmatrix} 0.9 \\ 0.45 \end{bmatrix} \quad \mathbf{n}^2 = \begin{bmatrix} 1 \\ 0 \end{bmatrix}$$

For Pattern 2:

$$\mathbf{n}^1 = \begin{bmatrix} 0.45 \\ 0.9 \end{bmatrix} \quad \mathbf{n}^2 = \begin{bmatrix} 0 \\ 1 \end{bmatrix}$$



The first row of the weight matrix is updated when $n_1^2(t)$ is active, and the second row of the weight matrix is updated when $n_2^2(t)$ is active.

شبکه‌ی گراسبرگ

پاسخ وزن‌های وفقی

RESPONSE OF ADAPTIVE WEIGHTS

فرض می‌کنیم دو الگوی ورودی متفاوت در دوره‌های زمانی 0.2 ثانیه‌ای به شبکه اعمال شوند.
فرض می‌کنیم لایه‌های ۱ و ۲ در مقایسه با وزن‌ها خیلی سریع‌تر همگرا می‌شوند و خروجی نرون‌ها در هر 0.2 ثانیه ثابت می‌شود.

Two different input patterns are alternately presented to the network for periods of 0.2 seconds at a time.

For Pattern 1:

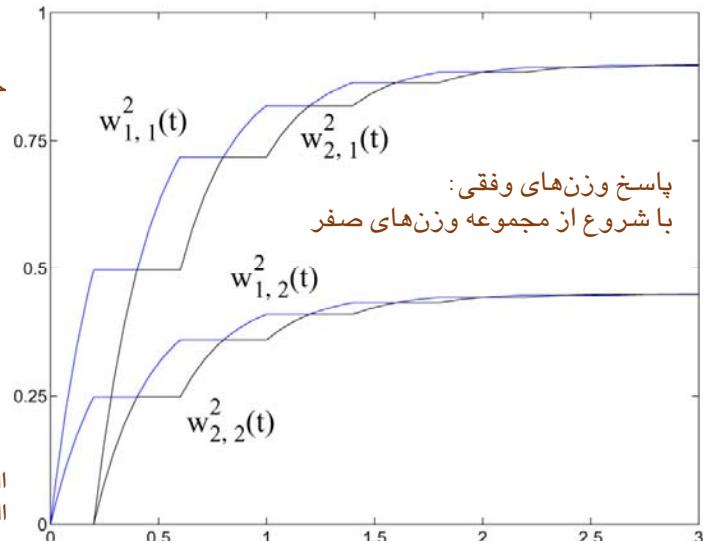
خروجی‌های لایه‌ی ۱ و ۲ برای دو الگوی ورودی

$$\mathbf{n}^1 = \begin{bmatrix} 0.9 \\ 0.45 \end{bmatrix} \quad \mathbf{n}^2 = \begin{bmatrix} 1 \\ 0 \end{bmatrix}$$

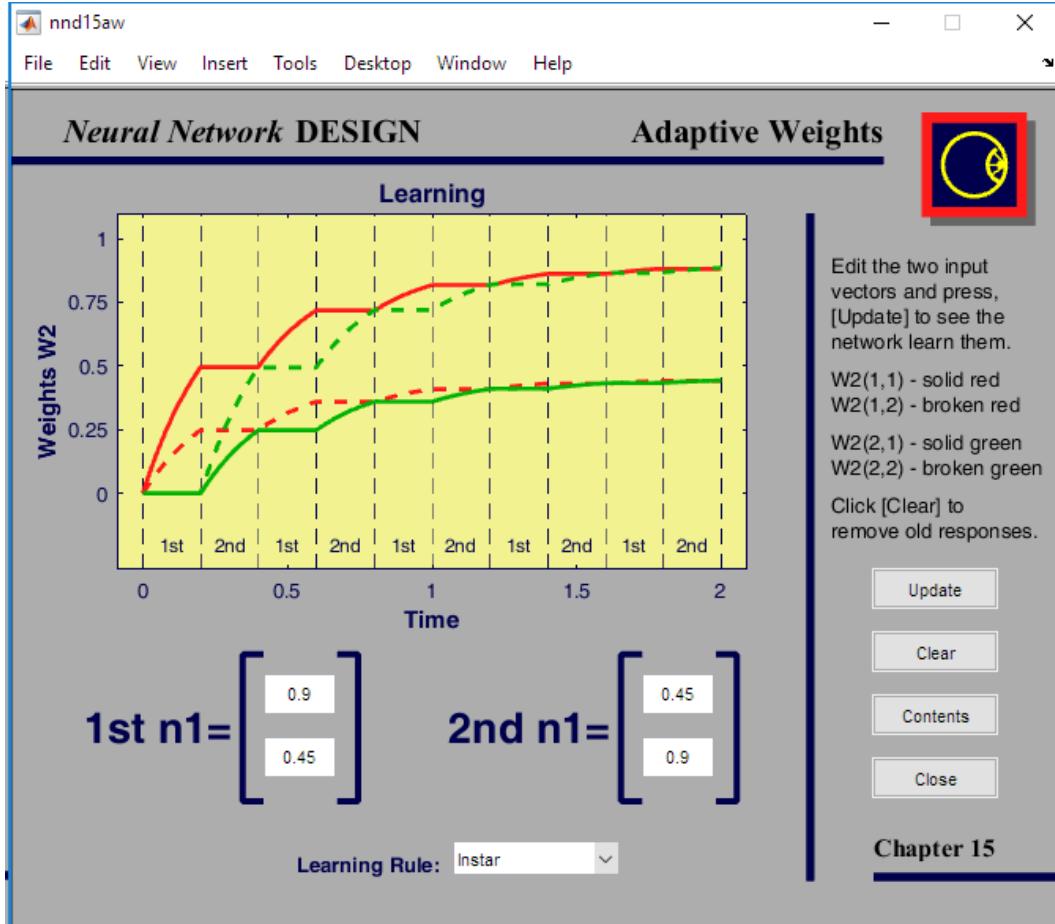
For Pattern 2:

$$\mathbf{n}^1 = \begin{bmatrix} 0.45 \\ 0.9 \end{bmatrix} \quad \mathbf{n}^2 = \begin{bmatrix} 0 \\ 1 \end{bmatrix}$$

الگوی اول توسط نرون اول از لایه‌ی ۲ و
الگوی دوم توسط نرون دوم از لایه‌ی ۲ کد شده است.



The first row of the weight matrix is updated when $n_1^2(t)$ is active, and the second row of the weight matrix is updated when $n_2^2(t)$ is active.



>> nnd15aw

شبکه‌ی گراسبرگ

۴

رابطه با
قانون
کوهونز

Relation to Kohonen Law



Grossberg Learning (Continuous-Time)

$$\frac{d[_i\mathbf{w}^2(t)]}{dt} = \alpha n_i^2(t) \{-[_i\mathbf{w}^2(t)] + \mathbf{n}^1(t)\}$$

Euler Approximation for the Derivative

$$\frac{d[_i\mathbf{w}^2(t)]}{dt} \approx \frac{_i\mathbf{w}^2(t + \Delta t) - _i\mathbf{w}^2(t)}{\Delta t}$$

Discrete-Time Approximation to Grossberg Learning

$$_i\mathbf{w}^2(t + \Delta t) = _i\mathbf{w}^2(t) + \alpha(\Delta t)n_i^2(t) \{-_i\mathbf{w}^2(t) + \mathbf{n}^1(t)\}$$

ارتباط قانون گراسبرگ با قانون کوهونن

RELATION TO KOHONEN LAW

قاعده‌ی یادگیری گراسبرگ، نسخه‌ی پیوسته-زمان قاعده‌ی یادگیری Instar است.
به علاوه: شبکه‌ی گراسبرگ در ساده‌ترین فرم خود، نسخه‌ی پیوسته-زمان شبکه‌ی رقابتی کوهونن است.

Grossberg Learning (Continuous-Time)

$$\frac{d[{}_i\mathbf{w}^2(t)]}{dt} = \alpha n_i^2(t) \{-[{}_i\mathbf{w}^2(t)] + \mathbf{n}^1(t)\}$$

Euler Approximation for the Derivative

$$\frac{d[{}_i\mathbf{w}^2(t)]}{dt} \approx \frac{{}_i\mathbf{w}^2(t + \Delta t) - {}_i\mathbf{w}^2(t)}{\Delta t}$$

Discrete-Time Approximation to Grossberg Learning

$${}_i\mathbf{w}^2(t + \Delta t) = {}_i\mathbf{w}^2(t) + \alpha(\Delta t)n_i^2(t) \{-{}_i\mathbf{w}^2(t) + \mathbf{n}^1(t)\}$$

Relation to Kohonen Law



Rearrange Terms

$$_i\mathbf{w}^2(t + \Delta t) = \{1 - \alpha(\Delta t)n_i^2(t)\}_i\mathbf{w}^2(t) + \alpha(\Delta t)n_i^2(t)\{\mathbf{n}^1(t)\}$$

Assume Winner-Take-All Competition

$$_{i^*}\mathbf{w}^2(t + \Delta t) = \{1 - \alpha'\}_{i^*}\mathbf{w}^2(t) + \{\alpha'\}\{\mathbf{n}^1(t)\} \quad \text{where} \quad \alpha' = \alpha(\Delta t)n_{i^*}^2(t)$$

Compare to Kohonen Rule

$$_{i^*}\mathbf{w}(q) = (1 - \alpha)_{i^*}\mathbf{w}(q - 1) + \alpha\mathbf{p}(q)$$

ارتباط قانون گراسبرگ با قانون کوهون

RELATION TO KOHONEN LAW

مرتب کردن مجدد جملات:

Rearrange Terms

$$_i\mathbf{w}^2(t + \Delta t) = \{1 - \alpha(\Delta t)n_i^2(t)\}_i\mathbf{w}^2(t) + \alpha(\Delta t)n_i^2(t)\{\mathbf{n}^1(t)\}$$

برای ساده‌تر شدن تحلیل‌ها فرض می‌کنیم در لایه‌ی ۲ ازتابع انتقال سریع‌تر از خطی استفاده شده باشد.
 ⇐ تنها یک نرون در لایه‌ی دوم دارای خروجی غیرصفر است: نرون i^* ⇐ فقط سطر i^* -ام از ماتریس وزن‌ها به روزرسانی می‌شود.

Assume Winner-Take-All Competition

$$_{i^*}\mathbf{w}^2(t + \Delta t) = \{1 - \alpha'\}_{i^*}\mathbf{w}^2(t) + \{\alpha'\}'\mathbf{n}^1(t) \quad \text{where} \quad \alpha' = \alpha(\Delta t)n_{i^*}^2(t)$$

این معادله تقریباً با قاعده‌ی کوهون برای شبکه‌های رقابتی یکسان می‌باشد.
 بردار وزن مربوط به نرون برنده به سمت \mathbf{n}^1 حرکت خواهد کرد (\mathbf{n}^1 نسخه‌ی نرمال‌شده‌ی الگوی ورودی).

Compare to Kohonen Rule

$$_{i^*}\mathbf{w}(q) = (1 - \alpha)_{i^*}\mathbf{w}(q - 1) + \alpha\mathbf{p}(q)$$

ارتباط قانون گراسبرگ با قانون کوهونن

مقایسه

RELATION TO KOHONEN LAW

سه فرق عمدی بین شبکه‌ی گراسبرگ با شبکه‌ی رقابتی کوهونن:

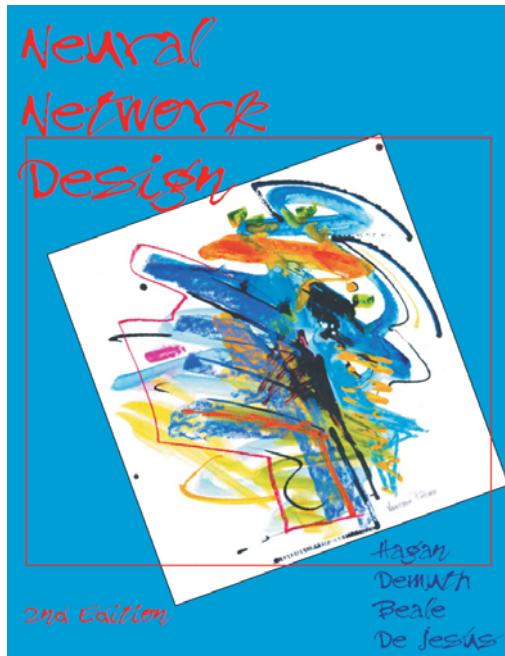
- شبکه‌ی گراسبرگ یک شبکه‌ی پیوسته-زمان است
(با مجموعه‌ای از معادلات دیفرانسیل غیرخطی توصیف می‌شود).
- لایه‌ی ۱ شبکه‌ی گراسبرگ به صورت خودکار بردارهای ورودی را نرم‌ال می‌کند.
- لایه‌ی ۲ شبکه‌ی گراسبرگ یک رقابت نرم (soft competition) ایجاد می‌کند.
در حالی که شبکه‌ی کوهونن رقابت «برندۀ همه را می‌خورد» دارد.
رقابت نرم به تعداد بیشتری از نرون‌های لایه‌ی ۲ امکان یادگیری می‌دهد.
- * شبکه‌ی گراسبرگ همانند یک شبکه‌ی نگاشت ویژگی عمل می‌کند.

شبکه‌ی گراسبرگ

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 18

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

18 Grossberg Network

Objectives	18-1
Theory and Examples	18-2
Biological Motivation: Vision	18-3
Illusions	18-4
Vision Normalization	18-8
Basic Nonlinear Model	18-9
Two-Layer Competitive Network	18-12
Layer 1	18-13
Layer 2	18-17
Choice of Transfer Function	18-20
Learning Law	18-22
Relation to Kohonen Law	18-24
Summary of Results	18-26
Solved Problems	18-30
Epilogue	18-42
Further Reading	18-43
Exercises	18-45

Objectives

This chapter is a continuation of our discussion of associative and competitive learning algorithms in Chapters 15 and 16. The Grossberg network described in this chapter is a self-organizing continuous-time competitive network. This will be the first time we have considered continuous-time recurrent networks, and we will introduce concepts here that will be further explored in Chapters 20 and 21. This Grossberg network is also the foundation for the adaptive resonance theory (ART) networks that we will present in Chapter 19.

We will begin with a discussion of the biological motivation for the Grossberg network in the human visual system. Although we will not cover this material in any depth, the Grossberg networks are so heavily influenced by biology that it is difficult to discuss his networks without putting them in their biological context. It is also important to note that biology provided the original inspirations for the field of artificial neural networks, and we should continue to look for inspiration there, as scientists continue to develop new understanding of brain function.

18-1