



## شبکه‌های عصبی مصنوعی

درس ۱۹

# نظریه‌ی تشدید و فقی

Adaptive Resonance Theory

کاظم فولادی قلعه

دانشکده مهندسی، پردیس فارابی

دانشگاه تهران



# Adaptive Resonance Theory (ART)

## نظریه‌ی تشدید و فقی

### ADAPTIVE RESONANCE THEORY (ART)

یک مشکل کلیدی در شبکه‌های رقابتی: پایداری یادگیری:  
هیچ تضمینی وجود ندارد که اعمال همه‌ی ورودی‌ها منجر به همگرایی شبکه شود.

**شبکه‌ی ART:** یک نوع تغییریافته از شبکه‌های رقابتی  
که به منظور غلبه بر مشکل پایداری یادگیری طراحی شده است.

نظریه‌ی تشدید و فقی

۱

# مروری بر تشدید وفقی

## نظریه‌ی تشدید و فقی

مشکل پایداری در شبکه‌های رقابتی

### ADAPTIVE RESONANCE THEORY (ART)

مشکل اصلی شبکه‌ی گراسبرگ و سایر شبکه‌های رقابتی:  
آنها همیشه قادر به ایجاد خوش‌ها یا دسته‌های پایدار نیستند.

گراسبرگ نشان داد که:

- اگر تعداد الگوهای ورودی زیاد نباشد و یا الگوهای ورودی دارای تعداد خوش‌های زیادی (نسبت به تعداد نرون‌های لایه‌ی دوم) نباشند؛ آن‌گاه یادگیری از پایداری مناسبی برخوردار خواهد بود.
- شبکه‌های رقابتی استاندارد در پاسخ به الگوهای ورودی دلخواه قادر یادگیری پایدار هستند.

دلیل ناپایداری یادگیری شبکه‌های رقابتی: قابلیت ورقپذیری (و انعطاف) آنها  
این قابلیت منجر به تأثیرپذیری بیشتر یادگیری از ورودی‌های تازه‌تر می‌شود.

گراسبرگ به این مشکل «معماه پایداری - انعطاف‌پذیری» می‌گوید.

## نظریه‌ی تشدید و فقی

مشکل پایداری در شبکه‌های رقابتی: معماهای پایداری - انعطاف‌پذیری

### STABILITY/PLASTICITY DILEMMA

#### معماهای پایداری - انعطاف‌پذیری:

سیستم چگونه می‌تواند علاوه بر تأثیرپذیری از نمونه‌های جدید در تقابل با الگوهای نامربوط پایدار باقی بماند؟

سیستم‌های بیولوژیکی در این مورد بسیار خوب عمل می‌کنند: برای مثال: انسان‌ها به آسانی قادر به تشخیص چهره‌ی مادرشان هستند، حتی اگر برای مدتی طولانی او را ندیده باشند و در این مدت افراد بسیار زیادی را ملاقات کرده باشند.

در راستای حل این معما، گراسبرگ و کارپنتر یک نظریه‌ی جدید با عنوان **(ART) نظریه‌ی تشدید و فقی** را توسعه دادند.

شبکه‌های ART بر مبنای عملکرد شبکه‌های گراسبرگ می‌باشند؛ یک نوآوری کلیدی در ART استفاده از مفهوم «انتظار» (Expectation) است.

## نظریه‌ی تشدید و فقی

مفهوم «انتظار»

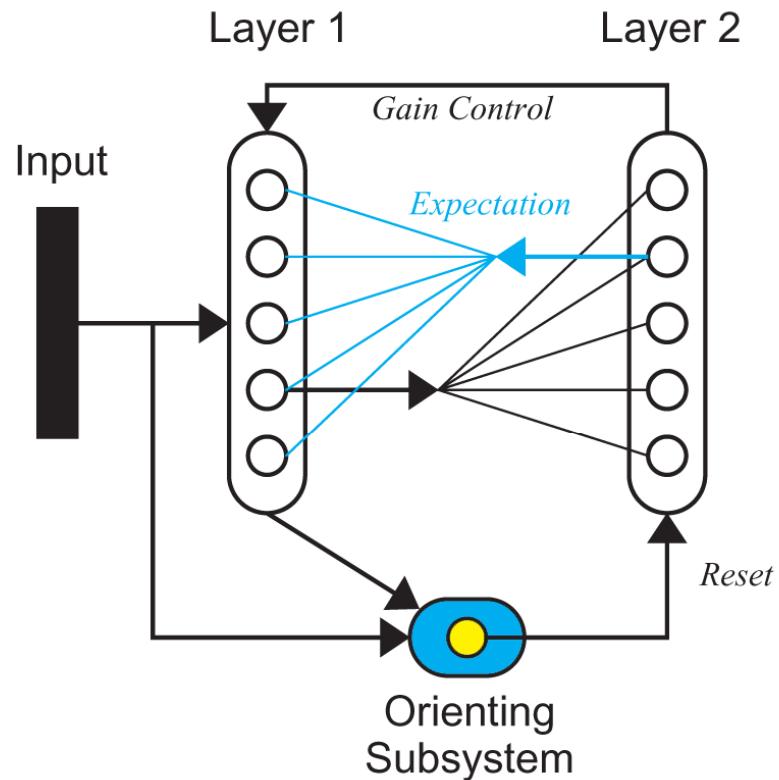
### “EXPECTATION” CONCEPT

انتظار: با ارائه‌ی هر یک از الگوهای ورودی به شبکه، آن ورودی با نزدیکترین بردار پروتوتایپ به خود مقایسه می‌شود (انتظار).

اگر میزان نزدیکی بردار ورودی به بردار پروتوتایپ کافی نباشد، یک بردار پروتوتایپ دیگر انتخاب می‌شود.

← الگوهای یادگرفته شده (الگوهای پروتوتایپ)، با توجه به یادگیری‌های جدیدتر دچار فرسایش نمی‌شوند.

# Basic ART Architecture

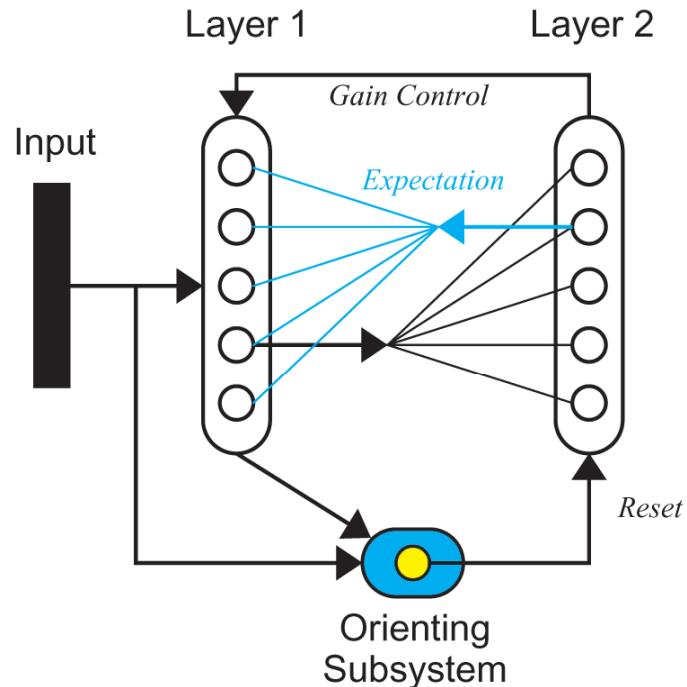


## نظریه‌ی تشذید و فقی

معماری پایه‌ی ART

BASIC ART ARCHITECTURE

**معماری ART1:** این شبکه خاص ورودی‌های دودویی طراحی شده است.



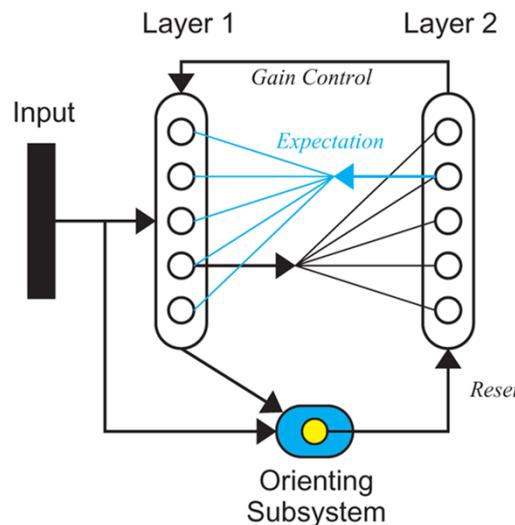
این شبکه، شکل تغییریافته‌ی شبکه‌ی گراسبرگ به‌منظور پایدارسازی فرآیند یادگیری است.

## نظریه‌ی تشذید و فقی

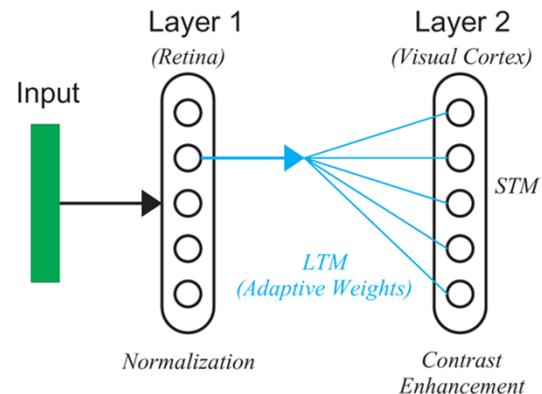
معماری پایه‌ی ART در مقایسه با گراسبرگ

BASIC ART ARCHITECTURE VS. GROSSBERG

ART



Grossberg



نوآوری‌ها در معماری ART1 :

- انتظار لایه‌ی دوم به لایه‌ی اول
- زیرسیستم گرادهنده
- کنترل بهره

## نظریه‌ی تشذید و فقی

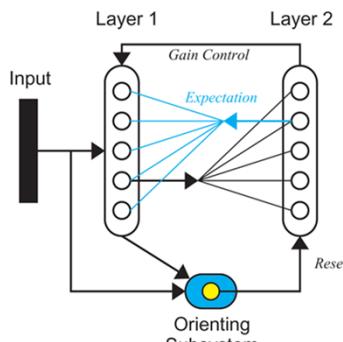
اتصالات لایه‌ها: لایه‌ی ۱ به ۲

### L1-L2 CONNECTIONS

اتصالات لایه‌ی ۱ به ۲ در شبکه‌های گراسبرگ (و ART) از نوع **Instar** است.  
این اتصالات عملیات خوشبندی را انجام می‌دهند.

- وقتی یک الگوی ورودی به شبکه اعمال می‌شود، پس از نرمال‌سازی در ماتریس وزن L1-L2 ضرب می‌شود.
- سپس در لایه‌ی ۲ با انجام عملیات رقابت، سطری از ماتریس وزن که در نزدیکترین وضعیت نسبت به بردار ورودی قرار دارد، تشخیص داده می‌شود.
- سپس این سطر به سمت بردار ورودی جابه‌جا می‌شود.  
 ↓

پس از تکمیل یادگیری، هر یک از سطرهای ماتریس وزن L1-L2 حاوی یکی از بردارهای پروتوتاپ خواهد بود که بازنمایی کننده‌ی یک خوش از بردارهای ورودی است.



## نظریه‌ی تشذید و فقی

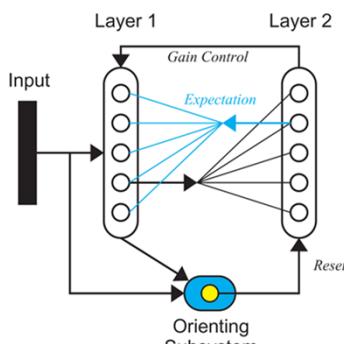
اتصالات لایه‌ها: لایه‌ی ۲ به ۱

### L2-L1 CONNECTIONS

در شبکه‌های ART روند یادگیری در مجموعه‌ای از اتصالات فیدبک از لایه‌ی ۲ به لایه‌ی ۱ نیز رخ می‌دهد.

اتصالات لایه‌ی ۲ به ۱ در شبکه‌های ART از نوع **Outstar** است.  
این اتصالات عملیات **به یادآوری** الگوها را انجام می‌دهند.

- هرگاه یک گره در لایه‌ی ۲ فعال شود، فیدبک، الگوی ورودی در لایه‌ی ۱ را بازتولید می‌کند (الگوی انتظار).
- سپس لایه‌ی ۱ یک مقایسه بین الگوی انتظار و الگوی ورودی انجام می‌دهد.
- اگر الگوی انتظار و الگوی ورودی، به اندازه‌ی کافی به هم نزدیک نباشند، زیرسیستم گرادهندگی **reset** در لایه‌ی ۲ ایجاد می‌کند: این نرون برندگی فعلی را غیرفعال کرده و مقدار انتظار جاری را حذف می‌کند.
- سپس یک رقابت جدید در لایه‌ی ۲ بدون حضور نرون برندگی قبلی انجام می‌شود.
- نرون برندگی جدید در لایه‌ی ۲ مقدار انتظار جدید را به لایه‌ی ۱ منعکس می‌کند (از طریق اتصالات L2-L1).



این فرآیند آنقدر تکرار می‌شود تا انتظار L2-L1 به اندازه‌ی کافی به الگوی ورودی نزدیک شود.



## Layer 1

Normalization

Comparison of input pattern and expectation

## L1-L2 Connections (Instars)

Perform clustering operation.

Each row of  $W^{1:2}$  is a prototype pattern.

## Layer 2

Competition, contrast enhancement

## L2-L1 Connections (Outstars)

Expectation

Perform pattern recall.

Each column of  $W^{2:1}$  is a prototype pattern

## Orienting Subsystem

Causes a reset when expectation does not match input

Disables current winning neuron

## نظریه‌ی تشدید و فقی

## زیرسیستم‌های ART

## ART SUBSYSTEMS

## لایه‌ی ۱

- نرمال‌سازی
- مقایسه‌ی الگوی ورودی و انتظار

## اتصالات لایه‌ی ۲ به ۱ (Instar)

- انجام عملیات خوشبندی
- هر سطر  $W^{1:2}$  یک الگوی پروتوتایپ است.

## لایه‌ی ۲

- رقابت، ارتقای کنتراست

## اتصالات لایه‌ی ۱ به ۲ (Outstar)

- انتظار
- انجام عملیات به یادآوری الگوها
- هر ستون  $W^{2:1}$  یک الگوی پروتوتایپ است.

## زیرسیستم گرادهند

- ایجاد یک reset هنگام عدم تطبیق انتظار با ورودی
- غیرفعال‌سازی نرون برنده‌ی فعلی

## Layer 1

Normalization

Comparison of input pattern and expectation

## L1-L2 Connections (Instars)

Perform clustering operation.

Each row of  $W^{1:2}$  is a prototype pattern.

## Layer 2

Competition, contrast enhancement

## L2-L1 Connections (Outstars)

Expectation

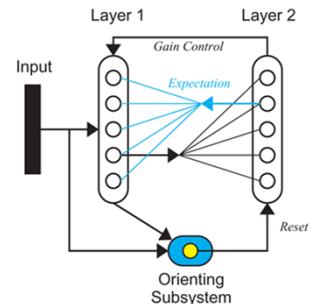
Perform pattern recall.

Each column of  $W^{2:1}$  is a prototype pattern

## Orienting Subsystem

Causes a reset when expectation does not match input

Disables current winning neuron



نظریه‌ی تشخیص و فقی

۳

لایه‌ی ۱

## نظریه‌ی تشذید و فقی

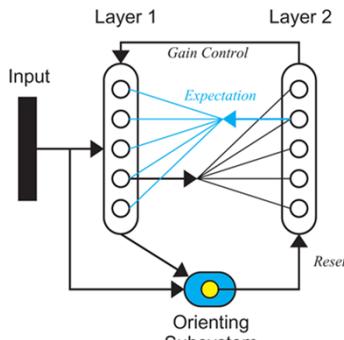
### لایه‌ی ۱

#### LAYER 1

هدف اصلی لایه‌ی ۱، مقایسه‌ی **الگوی ورودی** با **الگوی انتظار** از لایه‌ی ۲ می‌باشد.

(هر دوی این الگوها در ART1 دودویی هستند.)

- اگر این دو الگو، به اندازه‌ی کافی به هم نزدیک نباشند، آن‌گاه: زیرسیستم گرادهندگی **reset** در لایه‌ی ۲ ایجاد می‌کند.
- اگر این دو الگو، به اندازه‌ی کافی به هم نزدیک باشند، آن‌گاه: لایه‌ی ۱ الگوی انتظار و ورودی را با هم ترکیب کرده و یک الگوی پروتوتایپ جدید تولید می‌کند.

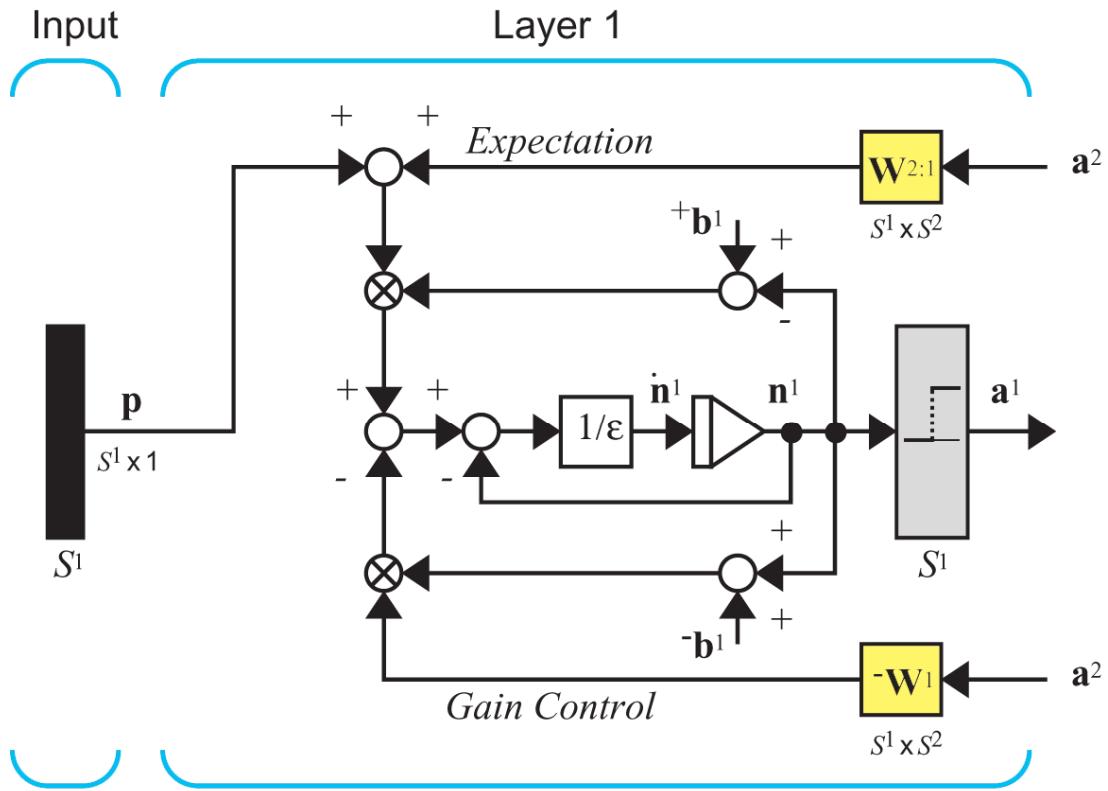


لایه‌ی ۱ شبکه‌ی ART1 بسیار شبیه به لایه‌ی ۱ شبکه‌ی گراسبرگ است.

تفاوت: در ورودی‌های تهییج‌گر و بازدارنده‌ی مدل شانتینگ است:  
در شبکه‌ی ART1 هیچگونه نرمال‌سازی در لایه‌ی ۱ انجام نمی‌شود;  
↓

نیازی به اتصالات «مرکز-روشن/پیرامون-خاموش»  
بین بردار ورودی و لایه‌ی ۱ وجود ندارد.

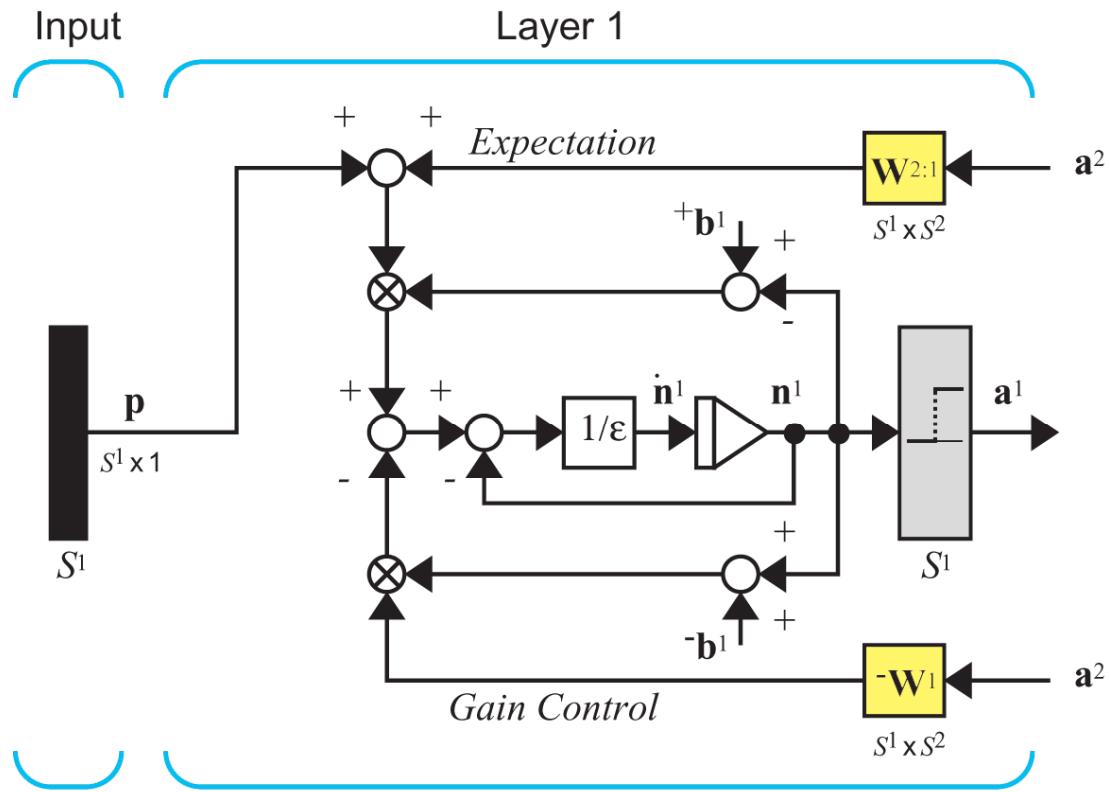
# Layer 1



$$\varepsilon \frac{d\mathbf{n}^1}{dt} = -\mathbf{n}^1 + (^+\mathbf{b}^1 - \mathbf{n}^1) \{ \mathbf{p} + \mathbf{W}_{2:1} \mathbf{a}^2 \} - (\mathbf{n}^1 + ^-\mathbf{b}^1) [^-\mathbf{W}_1] \mathbf{a}^2$$

## نظریه‌ی تشذید و فقی

لایه‌ی ۱

LAYER 1

$$\varepsilon \frac{dn^1}{dt} = -n^1 + (+b^1 - n^1) \{ p + W^{2:1} a^2 \} - (n^1 - b^1) [-W^1] a^2$$

# Layer 1 Operation



## Shunting Model

$$\varepsilon \frac{d\mathbf{n}^1(t)}{dt} = -\mathbf{n}^1(t) + \underbrace{(^+\mathbf{b}^1 - \mathbf{n}^1(t)) \{ \mathbf{p} + \mathbf{W}^{2:1} \mathbf{a}^2(t) \}}_{\text{Excitatory Input}} - (\mathbf{n}^1(t) + ^-\mathbf{b}^1) \underbrace{[ ^-\mathbf{W}^1 ] \mathbf{a}^2(t)}_{\text{Inhibitory Input}}$$

(Comparison with Expectation)                                  (Gain Control)

$$\mathbf{a}^1 = \mathbf{hardlim}^+(\mathbf{n}^1)$$

$$\mathbf{hardlim}^+(n) = \begin{cases} 1, & n > 0 \\ 0, & n \leq 0 \end{cases}$$

## نظریه‌ی تشذید و فقی

عملیات لایه‌ی ۱

LAYER 1 OPERATION

## Shunting Model

$$\varepsilon \frac{d\mathbf{n}^1(t)}{dt} = -\mathbf{n}^1(t) + \underbrace{(^+\mathbf{b}^1 - \mathbf{n}^1(t)) \{ \mathbf{p} + \mathbf{W}^{2:1} \mathbf{a}^2(t) \}}_{\text{Excitatory Input}} - (\mathbf{n}^1(t) + ^-\mathbf{b}^1) \underbrace{[ ^-\mathbf{W}^1 ] \mathbf{a}^2(t)}_{\text{Inhibitory Input}}$$

(Comparison with Expectation)                                  (Gain Control)

ورودی تهییج گر لایه‌ی ۱ شبکه‌ی ART1 شامل ترکیبی از الگوی ورودی و انتظار L1-L2 است.  
 ورودی بازدارنده‌ی لایه‌ی ۱ شبکه‌ی ART1 از سیگنال کنترل بهره‌ی لایه‌ی ۲ تشکیل می‌شود.

$$\mathbf{a}^1 = \mathbf{hardlim}^+(\mathbf{n}^1)$$

خروجی لایه‌ی ۱

$$\mathbf{hardlim}^+(n) = \begin{cases} 1, & n > 0 \\ 0, & n \leq 0 \end{cases}$$

# Excitatory Input to Layer 1



$$\mathbf{p} + \mathbf{W}^{2:1} \mathbf{a}^2(t)$$

Suppose that neuron  $j$  in Layer 2 has won the competition:

$$\mathbf{W}^{2:1} \mathbf{a}^2 = \begin{bmatrix} \mathbf{w}_1^{2:1} & \mathbf{w}_2^{2:1} & \dots & \mathbf{w}_j^{2:1} & \dots & \mathbf{w}_{S^2}^{2:1} \end{bmatrix} \begin{bmatrix} 0 \\ 0 \\ 0 \\ 1 \\ \vdots \end{bmatrix} = \mathbf{w}_j^{2:1} \quad (\text{$j$th column of } \mathbf{W}^{2:1})$$

Therefore the excitatory input is the sum of the input pattern and the L2-L1 expectation:

$$\mathbf{p} + \mathbf{W}^{2:1} \mathbf{a}^2 = \mathbf{p} + \mathbf{w}_j^{2:1}$$

## نظریه‌ی تشذید و فقی

ورودی تهییج‌گر به لایه‌ی ۱

### EXCITATORY INPUT TO LAYER 1

ورودی تهییج‌گر لایه‌ی ۱ برابر با مجموع بردار ورودی و انتظار L2-L1 است.

$$\mathbf{p} + \mathbf{W}^{2:1} \mathbf{a}^2(t)$$

به عنوان مثال: فرض کنید که نرون j-ام در لایه‌ی ۲ رقابت را برده باشد  $\leftarrow$  خروجی آن ۱ و خروجی سایر نرون‌ها ۰ است.

Suppose that neuron  $j$  in Layer 2 has won the competition:

$$\mathbf{W}^{2:1} \mathbf{a}^2 = \begin{bmatrix} \mathbf{w}_1^{2:1} & \mathbf{w}_2^{2:1} & \dots & \mathbf{w}_j^{2:1} & \dots & \mathbf{w}_{S^2}^{2:1} \end{bmatrix} \begin{bmatrix} 0 \\ 0 \\ \vdots \\ 1 \\ \vdots \end{bmatrix} = \mathbf{w}_j^{2:1} \quad (\text{jth column of } \mathbf{W}^{2:1})$$

پس ورودی تهییج‌گر لایه‌ی ۱ برابر با مجموع الگوی ورودی و انتظار L2-L1 خواهد بود.

Therefore the excitatory input is the sum of the input pattern and the L2-L1 expectation:

$$\mathbf{p} + \mathbf{W}^{2:1} \mathbf{a}^2 = \mathbf{p} + \mathbf{w}_j^{2:1}$$

هر ستون از ماتریس L2-L1 بازنمایی‌کننده‌ی یک انتظار متفاوت (الگوی پروتوتایپ) است.  
لایه‌ی ۱، الگوی ورودی را با انتظار ترکیب می‌کند (با استفاده از عملیات AND منطقی).





## Gain Control

$$[\mathbf{\tilde{W}}^1] \mathbf{a}^2(t)$$

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

The gain control will be one when Layer 2 is active (one neuron has won the competition), and zero when Layer 2 is inactive (all neurons having zero output).

## نظریه‌ی تشذید و فقی

ورودی بازدارنده به لایه‌ی ۱

### INHIBITORY INPUT TO LAYER 1

#### Gain Control

ورودی بازدارنده لایه‌ی ۱ برابر با جمله‌ی کنترل بهره است:

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

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

کاربرد کنترل بهره؟ پس از آشنایی با تحلیل حالت ماندگار لایه‌ی ۱

The gain control will be one when Layer 2 is active (one neuron has won the competition), and zero when Layer 2 is inactive (all neurons having zero output).

بنابراین، ورودی بازدارنده به هر یک از نرون‌های لایه‌ی ۱ برابر با مجموع همه‌ی خروجی‌های لایه‌ی ۲ خواهد بود.

چون از رقابت «برندۀ همه را می‌خورد» در لایه‌ی ۲ استفاده می‌کنیم، فقط یک عضو از  $\mathbf{a}^2$  غیر صفر خواهد بود.

پس ورودی کنترل بهره در لایه‌ی ۱ در صورت فعال بودن لایه‌ی ۲ برابر با ۱ و در صورت غیر فعال بودن آن ۰ خواهد بود.



$$\varepsilon \frac{dn_i^1}{dt} = -n_i^1 + (^+b^1 - n_i^1) \left\{ p_i + \sum_{j=1}^{S^2} w_{i,j}^{2:1} a_j^2 \right\} - (n_i^1 + ^-b^1) \sum_{j=1}^{S^2} a_j^2$$

Case I: Layer 2 inactive (each  $a_j^2 = 0$ )

$$\varepsilon \frac{dn_i^1}{dt} = -n_i^1 + (^+b^1 - n_i^1)\{p_i\}$$

In steady state:

$$0 = -n_i^1 + (^+b^1 - n_i^1)p_i = -(1 + p_i)n_i^1 + ^+b^1 p_i \quad \longrightarrow \quad n_i^1 = \frac{^+b^1 p_i}{1 + p_i}$$

Therefore, if Layer 2 is inactive:

$\mathbf{a}^1 = \mathbf{p}$

## نظریه‌ی تشذید و فقی

تحلیل حالت ماندگار: مورد «الف»

### STEADY STATE ANALYSIS: CASE I

پاسخ نرون  $i$ -ام از لایه‌ی ۱ به صورت زیر می‌باشد:

$$\epsilon \frac{dn_i^1}{dt} = -n_i^1 + (^+b^1 - n_i^1) \left\{ p_i + \sum_{j=1}^{S^2} w_{i,j}^{2:1} a_j^2 \right\} - (n_i^1 + ^-b^1) \sum_{j=1}^{S^2} a_j^2$$

که  $\epsilon < 0$  است  $\Leftrightarrow$  حافظه‌ی کوتاه‌مدت (خروجی نرون) بسیار سریع‌تر از حافظه‌ی بلند‌مدت (ماتریس وزن) تغییر می‌کند.

**لایه‌ی ۲ غیرفعال است** Case I: Layer 2 inactive (each  $a_j^2 = 0$ ) **مورد «الف»:**

$$\epsilon \frac{dn_i^1}{dt} = -n_i^1 + (^+b^1 - n_i^1) \{ p_i \}$$

مشتق صفر In steady state:

$$0 = -n_i^1 + (^+b^1 - n_i^1) p_i = -(1 + p_i) n_i^1 + ^+b^1 p_i \quad \rightarrow \quad n_i^1 = \frac{^+b^1 p_i}{1 + p_i}$$

پس اگر  $p_i = 0$  باشد آن‌گاه  $n_i^1 = ^+b^1/2 > 0$  است و اگر  $p_i = 1$  باشد آن‌گاه  $n_i^1 = 0$  خواهد بود.

Therefore, if Layer 2 is inactive:

$\mathbf{a}^1 = \mathbf{p}$

چون تابع انتقال لایه‌ی ۱،  $\text{hardlim}^+$  انتخاب شده است، پس  $\mathbf{p}^1 = \mathbf{a}^1$ .

$\Leftarrow$  هرگاه لایه‌ی ۲ غیرفعال باشد، خروجی لایه‌ی ۱ برابر با الگوی ورودی خواهد بود.





Case II: Layer 2 active (one  $a_j^2 = 1$ )

$$\epsilon \frac{dn_i^1}{dt} = -n_i^1 + (^+b^1 - n_i^1)\{p_i + w_{i,j}^{2:1}\} - (n_i^1 + ^-b^1)$$

In steady state:

$$\begin{aligned} 0 &= -n_i^1 + (^+b^1 - n_i^1)\{p_i + w_{i,j}^{2:1}\} - (n_i^1 + ^-b^1) \\ &= -(1 + p_i + w_{i,j}^{2:1} + 1)n_i^1 + (^+b^1(p_i + w_{i,j}^{2:1}) - ^-b^1) \end{aligned} \quad \longrightarrow \quad n_i^1 = \frac{^+b^1(p_i + w_{i,j}^{2:1}) - ^-b^1}{2 + p_i + w_{i,j}^{2:1}}$$

We want Layer 1 to combine the input vector with the expectation from Layer 2, using a logical AND operation:

$$\left. \begin{array}{l} n_i^1 < 0, \text{ if either } w_{i,j}^{2:1} \text{ or } p_i \text{ is equal to zero.} \\ n_i^1 > 0, \text{ if both } w_{i,j}^{2:1} \text{ or } p_i \text{ are equal to one.} \end{array} \right\} \begin{array}{l} ^+b^1(2) - ^-b^1 > 0 \\ ^+b^1 - ^-b^1 < 0 \end{array} \right\} ^+b^1(2) > ^-b^1 > ^+b^1$$

Therefore, if Layer 2 is active, and the biases satisfy these conditions:

$\mathbf{a}^1 = \mathbf{p} \cap \mathbf{w}_j^{2:1}$

## نظریه‌ی تشدید و فقی

تحلیل حالت ماندگار: مورد «ب»

### STEADY STATE ANALYSIS: CASE I

فرض می‌کنیم نرون  $j$ -ام برنده‌ی لایه‌ی ۲ باشد:

لایه‌ی ۲ فعال است

Case II: Layer 2 active (one  $a_j^2 = 1$ )

مورد «ب»:

$$\varepsilon \frac{dn_i^1}{dt} = -n_i^1 + (^+b^1 - n_i^1)\{p_i + w_{i,j}^{2:1}\} - (n_i^1 + ^-b^1)$$

(خروجی یک نرون ۱ و خروجی بقیه‌ی نرون‌ها ۰ است.)

In steady state: مشتق صفر

$$0 = -n_i^1 + (^+b^1 - n_i^1)\{p_i + w_{i,j}^{2:1}\} - (n_i^1 + ^-b^1) \rightarrow n_i^1 = \frac{^+b^1(p_i + w_{i,j}^{2:1}) - ^-b^1}{2 + p_i + w_{i,j}^{2:1}}$$

لایه‌ی ۱ باید بردار ورودی را با انتظار لایه‌ی ۲ (بیان شده با  $w^{2:1}_{ij}$ ) ترکیب نماید [الگوهای دودویی ←

We want Layer 1 to combine the input vector with the expectation from

Layer 2, using a logical AND operation:

$$\left. \begin{array}{l} n_i^1 < 0, \text{ if either } w_{ij}^{2:1} \text{ or } p_i \text{ is equal to zero.} \\ n_i^1 > 0, \text{ if both } w_{ij}^{2:1} \text{ or } p_i \text{ are equal to one.} \end{array} \right\} \begin{array}{l} ^+b^1(2) - ^-b^1 > 0 \\ ^+b^1 - ^-b^1 < 0 \end{array} \right\} ^+b^1(2) > ^-b^1 > ^+b^1$$

برای مثال، می‌توان قرار داد:  $^-b^1 = 1.5$  و  $^+b^1 = 1$ .

Therefore, if Layer 2 is active, and the biases satisfy these conditions:

$$\mathbf{a}^1 = \mathbf{p} \cap \mathbf{w}_j^{2:1}$$

در صورت ارضای شرایط فوق برای بایاس‌ها و فعال بودن لایه‌ی ۲، خروجی لایه‌ی ۱ به این صورت می‌شود.  
برای پیاده‌سازی عملیات AND به سیگنال «کنترل بهره» نیاز داریم.

## نظریه‌ی تشدید و فقی

استفاده از سیگنال «کنترل بهره» برای پیاده‌سازی عملیات AND

$$n_i^1 = \frac{^{+}b^1(p_i + w_{i,j}^{2:1}) - ^{-}b^1}{2 + p_i + w_{i,j}^{2:1}}$$

صورت کسر خروجی  $n_i^1$  را در نظر می‌گیریم:

جمله‌ی  $b^-$  در جمله‌ی مربوط به **کنترل بهره** ضرب می‌شود.  
در این مورد کنترل بهره برابر با ۱ است.

در صورت عدم وجود این جمله و در صورت بزرگتر از صفر بودن  $p_i$  یا  $w_{i,j}^{2:1}$   
حاصل معادله‌ی فوق و درنتیجه  $n_i^1$  بزرگتر از صفر خواهد بود.



به‌جای یک عملیات AND، یک عملیات OR خواهیم داشت.  
(مطابق بحثی که بخش زیرسیستم گرادهنده صورت می‌گیرد، انجام AND در لایه‌ی ۱ ضروری است).

زمانی که لایه‌ی ۲ غیرفعال است، جمله‌ی مربوط به **کنترل بهره** صفر است.  
(لازم است زیرا در این حالت انتظار داریم که لایه‌ی ۱ تنها به الگوی ورودی عکس العمل نشان دهد،  
زیرا هیچ انتظاری توسط لایه‌ی ۲ فعال نمی‌شود.)



If Layer 2 is inactive (each  $a^2_j = 0$ )

$$\mathbf{a}^1 = \mathbf{p}$$

If Layer 2 is active (one  $a^2_j = 1$ )

$$\mathbf{a}^1 = \mathbf{p} \cap \mathbf{w}_j^{2:1}$$

## نظریه‌ی تشذید و فقی

خلاصه‌ی لایه‌ی ۱

LAYER 1 SUMMARY

If Layer 2 is inactive (each  $a_j^2 = 0$ )

$$\mathbf{a}^1 = \mathbf{p}$$

If Layer 2 is active (one  $a_j^2 = 1$ )

$$\mathbf{a}^1 = \mathbf{p} \cap \mathbf{w}_j^{2:1}$$

# Layer 1 Example



$$\varepsilon = 1, {}^+b^1 = 1 \text{ and } {}^-b^1 = 1.5 \quad \mathbf{W}^{2:1} = \begin{bmatrix} 1 & 1 \\ 0 & 1 \end{bmatrix} \quad \mathbf{p} = \begin{bmatrix} 0 \\ 1 \end{bmatrix}$$

Assume that Layer 2 is active, and neuron 2 won the competition.

$$\left. \begin{aligned} (0.1) \frac{dn_1^1}{dt} &= -n_1^1 + (1-n_1^1)\{p_1 + w_{1,2}^{2:1}\} - (n_1^1 + 1.5) \\ &= -n_1^1 + (1-n_1^1)\{0 + 1\} - (n_1^1 + 1.5) = -3n_1^1 - 0.5 \end{aligned} \right\} \frac{dn_1^1}{dt} = -30n_1^1 - 5$$

$$\left. \begin{aligned} (0.1) \frac{dn_2^1}{dt} &= -n_2^1 + (1-n_2^1)\{p_2 + w_{2,2}^{2:1}\} - (n_2^1 + 1.5) \\ &= -n_2^1 + (1-n_2^1)\{1 + 1\} - (n_2^1 + 1.5) = -4n_2^1 + 0.5 \end{aligned} \right\} \frac{dn_2^1}{dt} = -40n_2^1 + 5$$

## نظریه‌ی تشذید و فقی

لایه‌ی ۱ : مثال

### LAYER 1 EXAMPLE

فرض می‌کنیم دو نرون در لایه‌ی ۲ و دو عنصر در ورودی داشته باشیم:

$$\varepsilon = 1, {}^+b^1 = 1 \text{ and } {}^-b^1 = 1.5 \quad \mathbf{W}^{2:1} = \begin{bmatrix} 1 & 1 \\ 0 & 1 \end{bmatrix} \quad \mathbf{p} = \begin{bmatrix} 0 \\ 1 \end{bmatrix}$$

ماتریس وزن  
ورودی

Assume that Layer 2 is active, and neuron 2 won the competition.

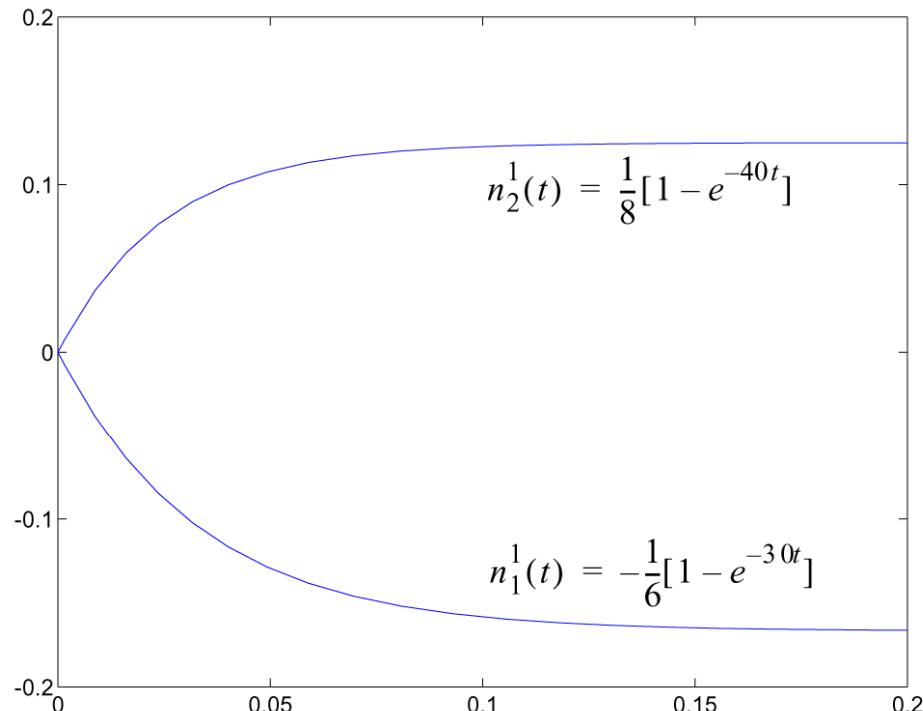
فرض می‌کنیم لایه‌ی ۲ فعال باشد و نرون ۲-ام آن رقابت را بردہ باشد:

$$\left. \begin{aligned} (0.1) \frac{dn_1^1}{dt} &= -n_1^1 + (1 - n_1^1) \{ p_1 + w_{1,2}^{2:1} \} - (n_1^1 + 1.5) \\ &= -n_1^1 + (1 - n_1^1) \{ 0 + 1 \} - (n_1^1 + 1.5) = -3n_1^1 - 0.5 \end{aligned} \right\} \quad \frac{dn_1^1}{dt} = -30n_1^1 - 5$$

معادلات عملیاتی لایه‌ی ۱ :

$$\left. \begin{aligned} (0.1) \frac{dn_2^1}{dt} &= -n_2^1 + (1 - n_2^1) \{ p_2 + w_{2,2}^{2:1} \} - (n_2^1 + 1.5) \\ &= -n_2^1 + (1 - n_2^1) \{ 1 + 1 \} - (n_2^1 + 1.5) = -4n_2^1 + 0.5 \end{aligned} \right\} \quad \frac{dn_2^1}{dt} = -40n_2^1 + 5$$

# Example Response



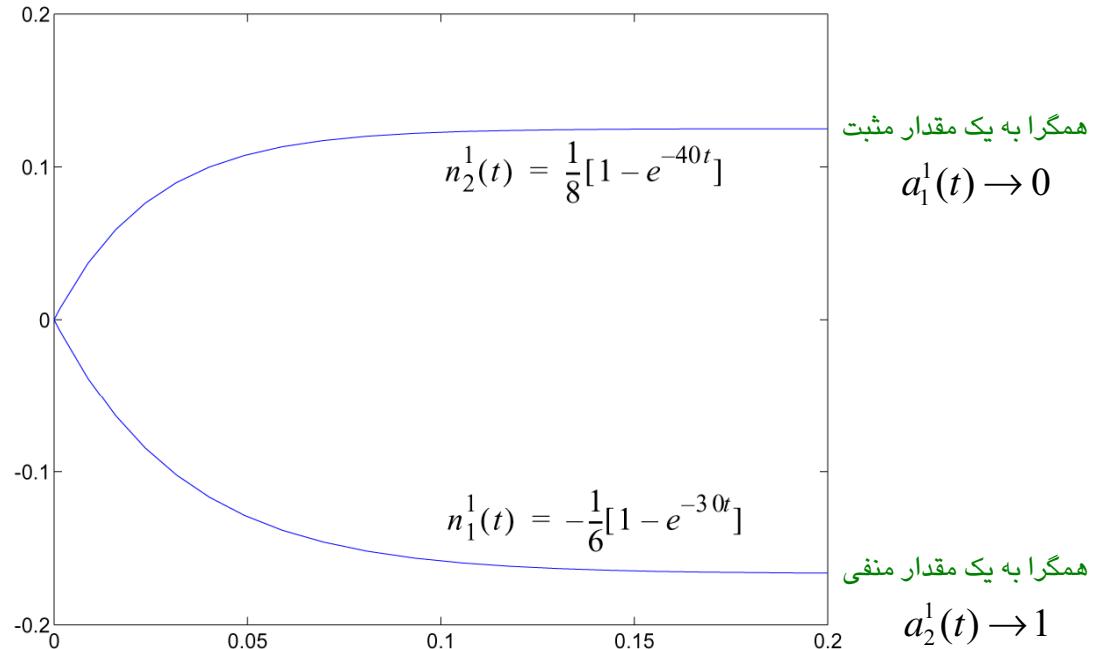
$$\mathbf{p} \cap \mathbf{w}_2^{2:1} = \begin{bmatrix} 0 \\ 1 \end{bmatrix} \cap \begin{bmatrix} 1 \\ 1 \end{bmatrix} = \begin{bmatrix} 0 \\ 1 \end{bmatrix} = \mathbf{a}^1$$

## نظریه‌ی تشدید و فقی

لایه‌ی ۱ : مثال: پاسخ

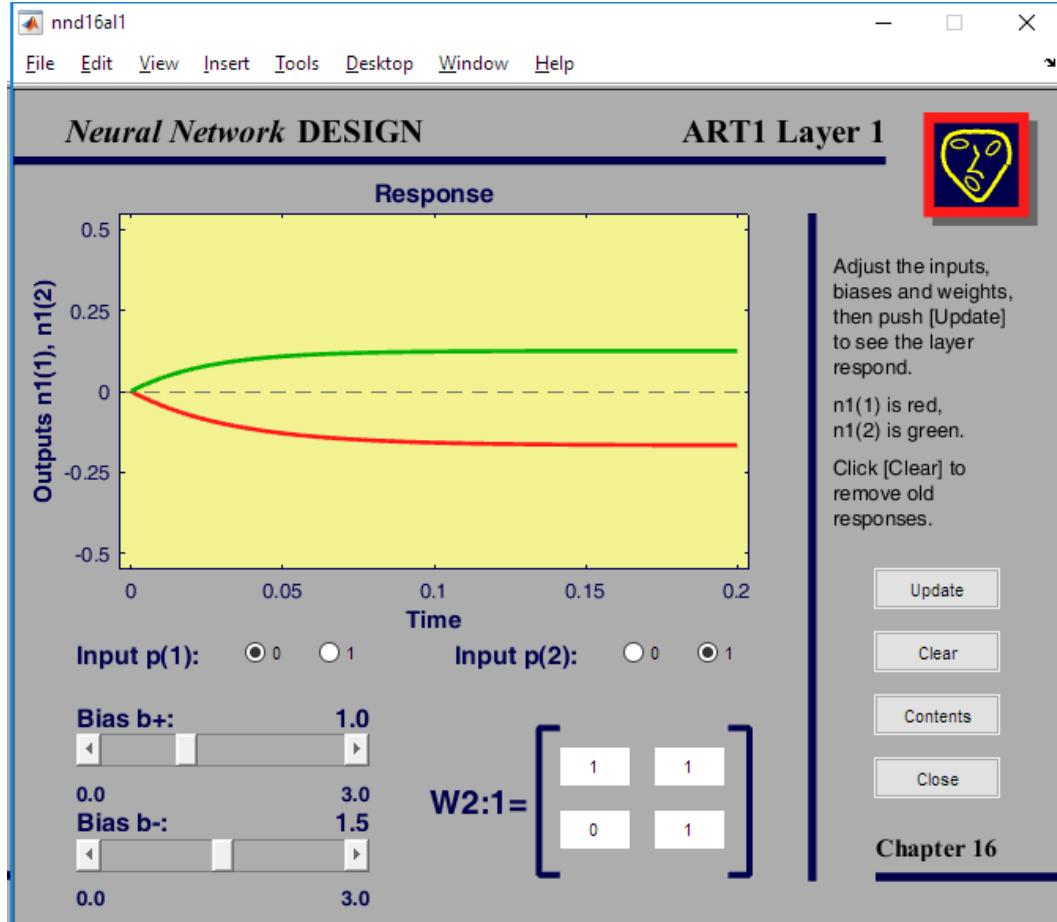
EXAMPLE RESPONSE

با فرض شرایط آغازین صفر



$$\mathbf{p} \cap \mathbf{w}_2^{2:1} = \begin{bmatrix} 0 \\ 1 \end{bmatrix} \cap \begin{bmatrix} 1 \\ 1 \end{bmatrix} = \begin{bmatrix} 0 \\ 1 \end{bmatrix} = \mathbf{a}^1$$

این نتایج با تحلیل ما از حالت ماندگار  
همخوانی دارند:



>> nnd16al1

نظریه‌ی تشخیص و فقی

۳

لایه‌ی ۲

## نظریه‌ی تشذید و فقی

لایه‌ی ۲

### LAYER 2

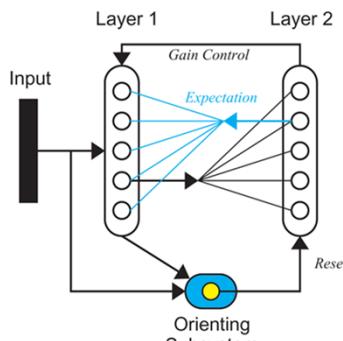
هدف اصلی لایه‌ی ۲، ارتقای کنتراست در **الگوی خروجی آن** است.

در این پیاده‌سازی، ارتقای کنتراست از طریق یک رقابت «برندۀ همه را می‌خورد» انجام می‌شود.  
 نرون دارای بیشترین ورودی دارای خروجی غیر صفر است.  $\Leftarrow$

در لایه‌ی ۲، انTEGRالگیر دارای قابلیت بازنشانی است:

خروجی‌هایی که بازنشانی می‌شوند، برای یک دوره‌ی طولانی در صفر باقی می‌مانند.  
 (دوره‌ی طولانی = مدتی که یک انطباق کافی رخ بدهد و وزن‌ها به روزرسانی شوند.)

پیشنهاد کارپتر و گراسبرگ برای پیاده‌سازی مکانیسم بازنشانی: استفاده از یک درگاه دوقطبی ( $\leftarrow$  مدل پیچیده‌تر در ART3)



لایه‌ی ۲ شبکه‌ی ART1 بسیار شبیه به لایه‌ی ۲ شبکه‌ی گراسبرگ است.

#### تفاوت‌ها:

- استفاده از انTEGRالگیر با قابلیت RESET در شبکه‌ی ART1
- استفاده از دو تابع انتقال

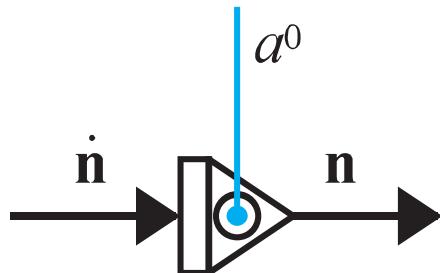
## نظریه‌ی تشدید و فقی

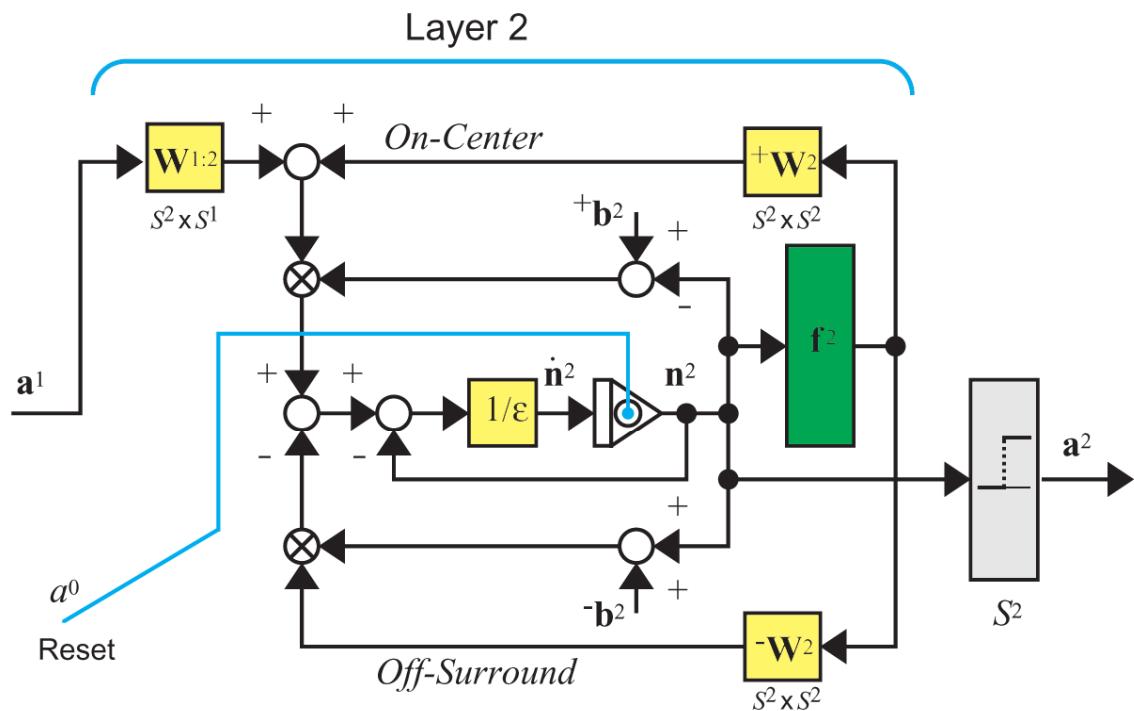
انتگرال‌گیر با قابلیت بازنشانی

### INTEGRATOR WITH RESET CAPABILITY

#### انتگرال‌گیر با قابلیت بازنشانی

در این نوع انتگرال‌گیر، هر خروجی مثبت به  $0$  بازنشانی (reset) می‌شود اگر سیگنال  $a^0$  مثبت باشد.



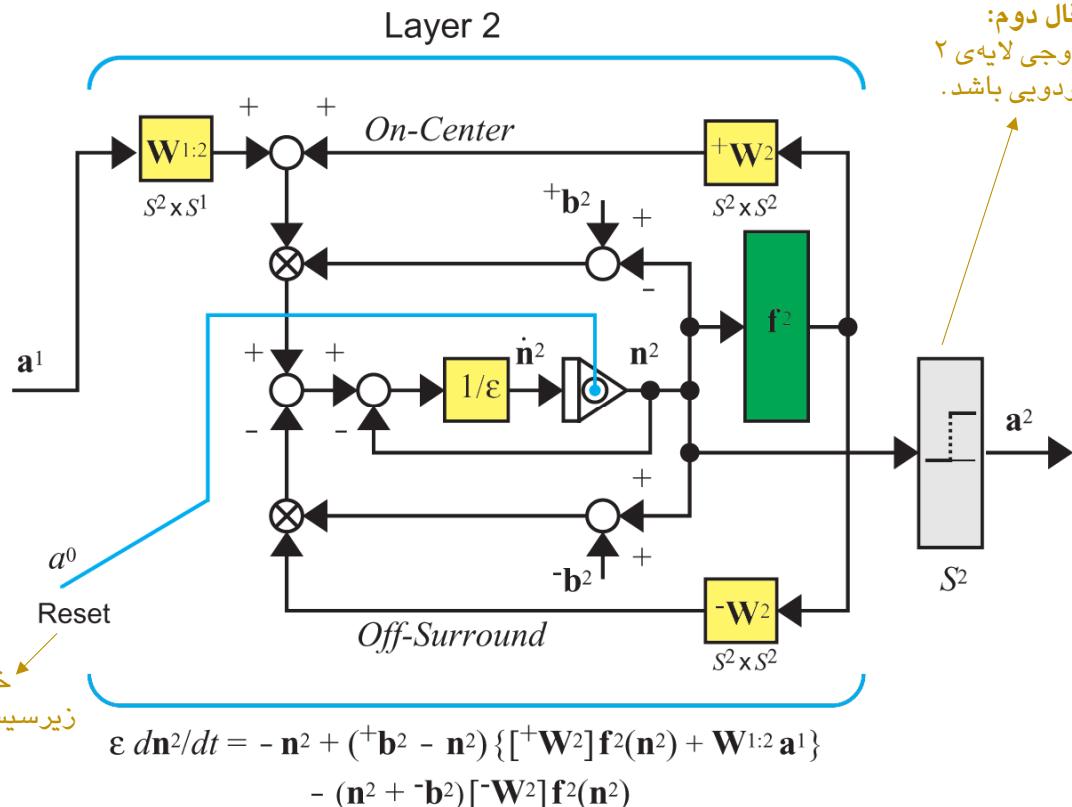


$$\begin{aligned} \varepsilon \frac{d\mathbf{n}^2}{dt} = & -\mathbf{n}^2 + (^+\mathbf{b}^2 - \mathbf{n}^2) \{ (^+\mathbf{W}^2) \mathbf{f}^2(\mathbf{n}^2) + \mathbf{W}^{1:2} \mathbf{a}^1 \} \\ & - (\mathbf{n}^2 + ^-\mathbf{b}^2) (^-\mathbf{W}^2) \mathbf{f}^2(\mathbf{n}^2) \end{aligned}$$

## نظریه‌ی تشذید و فقی

لایه‌ی ۲

Layer 2



خروجی زیرسیستم گرادهنده

# Layer 2 Operation



## Shunting Model

$$\varepsilon \frac{d\mathbf{n}^2(t)}{dt} = -\mathbf{n}^2(t)$$

$$\boxed{\quad + (^+ \mathbf{b}^2 - \mathbf{n}^2(t)) \underbrace{[{}^+ \mathbf{W}^2] \mathbf{f}^2(\mathbf{n}^2(t)) + \mathbf{W}^{1:2} \mathbf{a}^1}_{\text{Excitatory Input}} \quad } \\
 \qquad \qquad \qquad \overbrace{\qquad \qquad \qquad}^{\substack{\text{On-Center} \\ \text{Feedback} \\ \text{Adaptive} \\ \text{Instars}}} \\
 \qquad \qquad \qquad - (\mathbf{n}^2(t) + {}^- \mathbf{b}^2) \underbrace{{}^- \mathbf{W}^2] \mathbf{f}^2(\mathbf{n}^2(t))}_{\substack{\text{Off-Surround} \\ \text{Feedback} \\ \text{Inhibitory} \\ \text{Input}}} \\
 \qquad \qquad \qquad \overbrace{\qquad \qquad \qquad}^{\substack{\text{Excitatory} \\ \text{Input} \\ \text{Inhibitory} \\ \text{Input}}}$$

## نظریه‌ی تشذید و فقی

## عملیات لایه‌ی ۲

## LAYER 2 OPERATION

## Shunting Model

$$\varepsilon \frac{d\mathbf{n}^2(t)}{dt} = -\mathbf{n}^2(t)$$

اتصالات فیدبک  
(مشابه لایه ۱ و ۲)  
گراسبرگ

وزن‌های ورقی  
(معادل با)  
شبکه‌ی کوهونن

On-Center  
Feedback

Adaptive  
Instars

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

Excitatory

Input

ورودی تهییج‌گر

اتصالات فیدبک  
(مشابه لایه ۱ و ۲)  
گراسبرگ

Off-Surround  
Feedback

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

Inhibitory  
Input

ورودی بازدارنده

سطرهای ماتریس  $\mathbf{W}^{1:2}$  پس از آموزش  
بازنمایی‌کننده‌ی الگوهای پرتوتایپ می‌باشد.

# Layer 2 Example



$$\varepsilon = 0.1 \quad {}^+\mathbf{b}^2 = \begin{bmatrix} 1 \\ 1 \end{bmatrix} \quad {}^-\mathbf{b}^2 = \begin{bmatrix} 1 \\ 1 \end{bmatrix} \quad \mathbf{W}^{1:2} = \begin{bmatrix} ({}^1\mathbf{w}^{1:2})^T \\ ({}^2\mathbf{w}^{1:2})^T \end{bmatrix} = \begin{bmatrix} 0.5 & 0.5 \\ 1 & 0 \end{bmatrix}$$

$$f^2(n) = \begin{cases} 10(n)^2, & n \geq 0 \\ 0, & n < 0 \end{cases} \quad (\text{Faster than linear, winner-take-all})$$

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

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

## نظریه‌ی تشذید و فقی

لایه‌ی ۲ : مثال

### LAYER 2 EXAMPLE

یک لایه با دو نرون و پارامترهای زیر را در نظر می‌گیریم:

$$\varepsilon = 0.1 \quad +\mathbf{b}^2 = \begin{bmatrix} 1 \\ 1 \end{bmatrix} \quad -\mathbf{b}^2 = \begin{bmatrix} 1 \\ 1 \end{bmatrix} \quad \mathbf{W}^{1:2} = \begin{bmatrix} ({_1\mathbf{w}}^{1:2})^T \\ ({_2\mathbf{w}}^{1:2})^T \end{bmatrix} = \begin{bmatrix} 0.5 & 0.5 \\ 1 & 0 \end{bmatrix}$$

تابع انتقال سریع‌تر از خطی  
 $\Leftrightarrow$  برنده همه را می‌خورد.)

$$f^2(n) = \begin{cases} 10(n)^2, & n \geq 0 \\ 0, & n < 0 \end{cases} \quad (\text{Faster than linear, winner-take-all})$$

معادلات عملیاتی لایه‌ی ۲ :

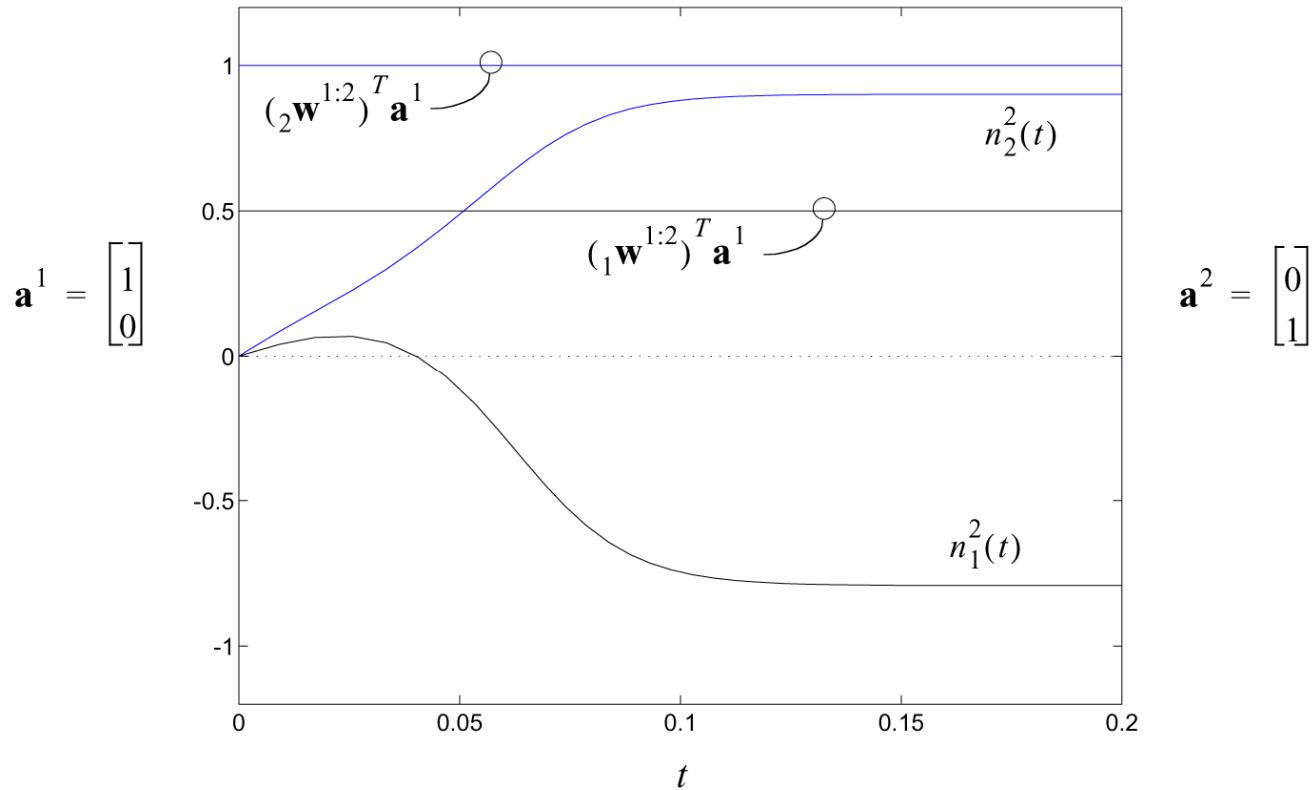
$$(0.1) \frac{dn_1^2(t)}{dt} = -n_1^2(t) + (1 - n_1^2(t)) \left\{ f^2(n_1^2(t)) + ({_1\mathbf{w}}^{1:2})^T \mathbf{a}^1 \right\} - (n_1^2(t) + 1) f^2(n_2^2(t))$$

مشابه معادلات لایه ۲ شبکه گراسبرگ، به استثنای اینکه  $-b^2 = 1 \Leftrightarrow n_1^2 = 1$  و  $n_2^2 = 1$  در بازه‌ی  $[-1, +1]$  قرار می‌گیرند.

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

ورودی‌های لایه‌ی ۲ : ضرب داخلی الگوهای پروتوتاپ (سطرهای ماتریس  $\mathbf{W}^{1:2}$ ) با خروجی لایه‌ی ۱ ( $\mathbf{a}^1$ )

# Example Response

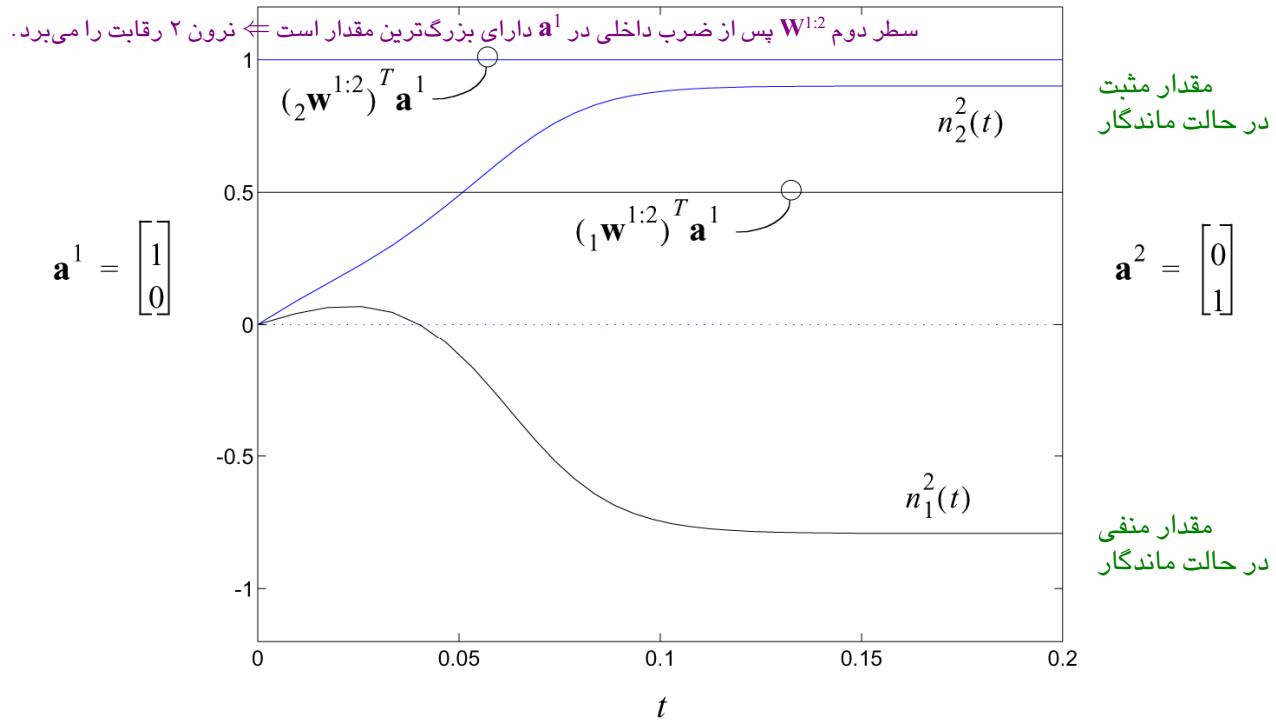


## نظریه‌ی تشدید و فقی

لایه‌ی ۲ : مثال: پاسخ

## EXAMPLE RESPONSE

پس از انجام رقابت، فقط یک نرون دارای خروجی ۱ خواهد بود و خروجی سایر نرون‌ها صفر است (تابع انتقال hardlim).





$$a_i^2 = \begin{cases} 1 , & \text{if } ({\mathbf{w}}^{1:2})^T \mathbf{a}^1 = \max[({\mathbf{w}}^{1:2})^T \mathbf{a}^1] \\ 0 , & \text{otherwise} \end{cases}$$

## نظریه‌ی تشذید و فقی

خلاصه‌ی لایه‌ی ۲

LAYER 2 SUMMARY

$$a_i^2 = \begin{cases} 1 , & \text{if}(({}_i\mathbf{w}^{1:2})^T \mathbf{a}^1 = \max[({}_j\mathbf{w}^{1:2})^T \mathbf{a}^1]) \\ 0 , & \text{otherwise} \end{cases}$$

خروجی نرون برنده ۱ و سایر نرون‌ها ۰



>> nnd16al2

نظریه‌ی تشخیص و فقی

۴

## زیرسیستم گرادهنده

## نظریه‌ی تشذید و فقی

### زیرسیستم گرادهند

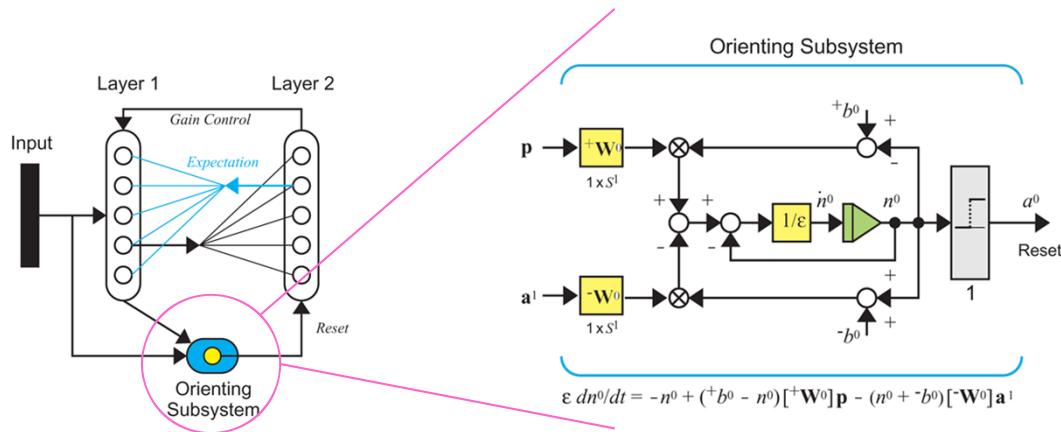
#### ORIENTING SUBSYSTEM

هدف زیرسیستم گرادهند: تشخیص وجود انطباق کافی بین انتظار L2-L1 ( $a^1$ ) و الگوی ورودی ( $p$ ).

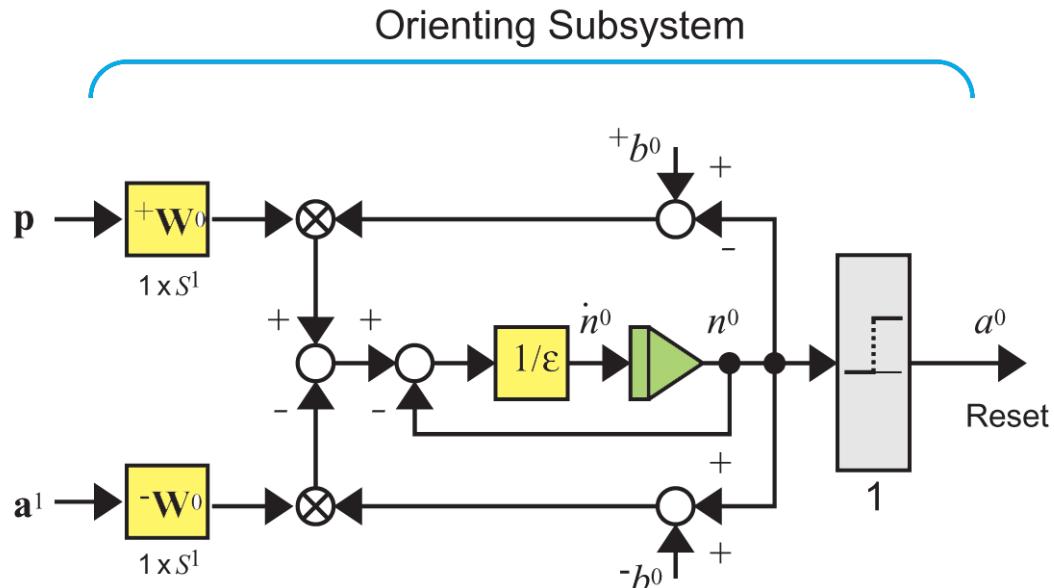
(زیرسیستم گرادهند یک جزء کلیدی در معماری ART است)

اگر انطباق کافی وجود نداشته باشد،

زیرسیستم گرادهند باید یک سیگنال بازنشانی reset به لایه‌ی ۲ ارسال کند.  
این سیگنال بازنشانی منجر به یک بازدارندگی طولانی مدت بر روی نرون برنده می‌شود  
و در نتیجه سایر نرون‌ها را قادر به پیروزی در رقابت می‌کند.



# Orienting Subsystem



$$\varepsilon \frac{dn^0}{dt} = -n^0 + (+b^0 - n^0)[+W^0]p - (n^0 + -b^0)[-W^0]a^1$$

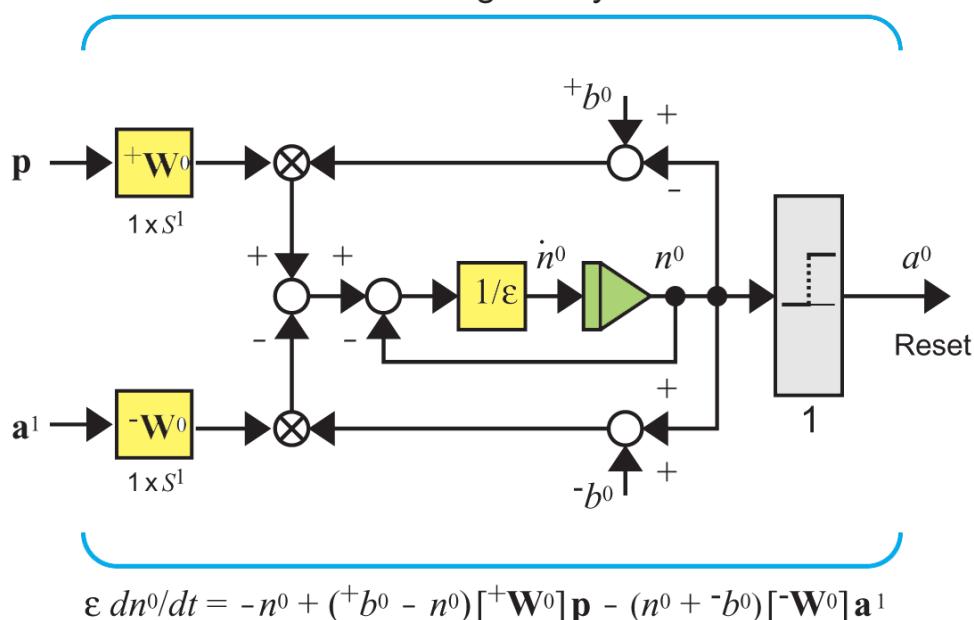
Purpose: Determine if there is a sufficient match between the L2-L1 expectation ( $a^1$ ) and the input pattern ( $p$ ).

## نظریه‌ی تشذید و فقی

زیرسیستم گرادهند

ORIENTING SUBSYSTEM

Orienting Subsystem



Purpose: Determine if there is a sufficient match between the L2-L1 expectation ( $a^1$ ) and the input pattern ( $p$ ).



$$\varepsilon \frac{dn^0(t)}{dt} = -n^0(t) + (^+b^0 - n^0(t))\{^+W^0 p\} - (n^0(t) + ^-b^0)\{-W^0 a^1\}$$

Excitatory Input

$${}^+W^0 p = [\alpha \ \alpha \dots \ \alpha] p = \alpha \sum_{j=1}^{S^1} p_j = \alpha \|p\|^2$$

Inhibitory Input

$$^-W^0 a^1 = [\beta \ \beta \dots \ \beta] a^1 = \beta \sum_{j=1}^{S^1} a_j^1(t) = \beta \|a^1\|^2$$

When the excitatory input is larger than the inhibitory input, the Orienting Subsystem will be driven on.

## نظریه‌ی تشید و فقی

عملیات زیرسیستم گرادهنده

### ORIENTING SUBSYSTEM OPERATION

یک مدل شانتینگ:

$$\varepsilon \frac{dn^0(t)}{dt} = -n^0(t) + (+b^0 - n^0(t))\{ {}^+ \mathbf{W}^0 \mathbf{p} \} - (n^0(t) + {}^- b^0)\{ {}^- \mathbf{W}^0 \mathbf{a}^1 \}$$

Excitatory Input

$\rightarrow {}^+ \mathbf{W}^0 \mathbf{p} = [\alpha \ \alpha \ \dots \ \alpha] \mathbf{p} = \alpha \sum_{j=1}^{S^1} p_j = \alpha \|\mathbf{p}\|^2$

چون بردار  $\mathbf{p}$  دودویی است.

Inhibitory Input

$\rightarrow {}^- \mathbf{W}^0 \mathbf{a}^1 = [\beta \ \beta \ \dots \ \beta] \mathbf{a}^1 = \beta \sum_{j=1}^{S^1} a_j^1(t) = \beta \|\mathbf{a}^1\|^2$

When the excitatory input is larger than the inhibitory input,  
the Orienting Subsystem will be driven on.

هرگاه ورودی تهییج‌گر بزرگتر از ورودی بازدارنده باشد، زیرسیستم گرادهنده فعال می‌شود.

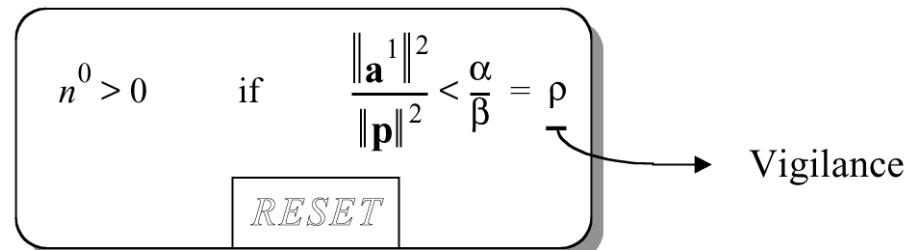
# Steady State Operation



$$\begin{aligned}
 0 &= -n^0 + (^+b^0 - n^0)\{\alpha\|\mathbf{p}\|^2\} - (n^0 + ^-b^0)\left\{\beta\|\mathbf{a}^1\|^2\right\} \\
 &= -(1 + \alpha\|\mathbf{p}\|^2 + \beta\|\mathbf{a}^1\|^2)n^0 + ^+b^0(\alpha\|\mathbf{p}\|^2) - ^-b^0(\beta\|\mathbf{a}^1\|^2)
 \end{aligned}$$

$$n^0 = \frac{^+b^0(\alpha\|\mathbf{p}\|^2) - ^-b^0(\beta\|\mathbf{a}^1\|^2)}{(1 + \alpha\|\mathbf{p}\|^2 + \beta\|\mathbf{a}^1\|^2)}$$

Let  ${}^+b^0 = {}^-b^0 = 1$



Since  $\mathbf{a}^1 = \mathbf{p} \cap \mathbf{w}_j^{2:1}$ , a reset will occur when there is enough of a mismatch between  $\mathbf{p}$  and  $\mathbf{w}_j^{2:1}$ .

## نظریه‌ی تشذید و فقی

عملیات زیرسیستم گرادهند در حالت ماندگار

### STEADY STATE OPERATION

(مشتق در حالت  
ماندگار صفر است)

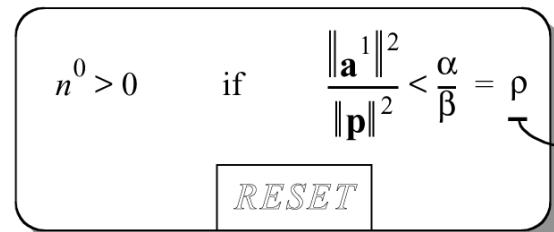
$$0 = -n^0 + (^+b^0 - n^0)\{\alpha\|\mathbf{p}\|^2\} - (n^0 + ^-b^0)\left\{\beta\|\mathbf{a}^1\|^2\right\}$$

$$= -(1 + \alpha\|\mathbf{p}\|^2 + \beta\|\mathbf{a}^1\|^2)n^0 + ^+b^0(\alpha\|\mathbf{p}\|^2) - ^-b^0(\beta\|\mathbf{a}^1\|^2)$$

$$n^0 = \frac{^+b^0(\alpha\|\mathbf{p}\|^2) - ^-b^0(\beta\|\mathbf{a}^1\|^2)}{(1 + \alpha\|\mathbf{p}\|^2 + \beta\|\mathbf{a}^1\|^2)}$$

فرض می‌کنیم:  ${}^+b^0 = {}^-b^0 = 1$

در صورت فعال بودن لایه‌ی ۲،  
 $\mathbf{a}^1 = \mathbf{p} \cap \mathbf{w}_j^{2:1}$  خواهد بود.  
پس  $\|\mathbf{p}\|^2 \geq \|\mathbf{a}^1\|^2$  و  
زیرسیستم گرادهند در صورت  
عدم تطابق کافی بین  $\mathbf{p}$  و  $\mathbf{w}_j^{2:1}$   
منجر به بازنشانی می‌شود.



میزان عدم تطابق برای انجام  
بازنشانی، توسط پارامتر  
هوشیاری  $\rho$  تعیین می‌شود.  
→ Vigilance  
پارامتر هوشیاری

Since  $\mathbf{a}^1 = \mathbf{p} \cap \mathbf{w}_j^{2:1}$ , a reset will occur when there is enough of a mismatch between  $\mathbf{p}$  and  $\mathbf{w}_j^{2:1}$ .

## نظریه‌ی تشدید و فقی

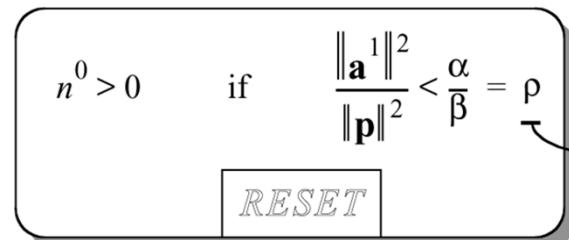
زیرسیستم گرادهند: پارامتر هوشیاری

### VIGILANCE PARAMETER

## پارامتر هوشیاری

$$0 < \rho < 1$$

- اگر نزدیک به ۱ باشد، عملیات reset در صورتی که  $\mathbf{p}^1$  به  $\mathbf{a}^1$  نزدیک نباشد رخ می‌دهد.
  - اگر نزدیک به ۰ باشد، نیازی به نزدیک بودن  $\mathbf{a}^1$  به  $\mathbf{p}$  برای جلوگیری از reset وجود ندارد.
- \* پارامتر هوشیاری میزان سختگیری روال خوشبندی توسط بردارهای پروتوتاپ را مشخص می‌کند.



میزان عدم تطابق برای انجام  
بازنشانی، توسط پارامتر  
هوشیاری  $\rho$  تعیین می‌شود.  
→ Vigilance  
پارامتر هوشیاری

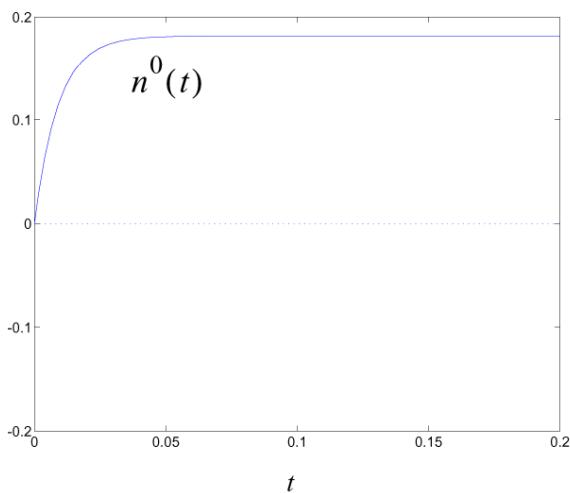
# Orienting Subsystem Example



$$\varepsilon = 0.1, \alpha = 3, \beta = 4 (\rho = 0.75) \quad \mathbf{p} = \begin{bmatrix} 1 \\ 1 \end{bmatrix} \quad \mathbf{a}^1 = \begin{bmatrix} 1 \\ 0 \end{bmatrix}$$

$$(0.1) \frac{dn^0(t)}{dt} = -n^0(t) + (1 - n^0(t))\{3(p_1 + p_2)\} - (n^0(t) + 1)\{4(a_1^1 + a_2^1)\}$$

$$\frac{dn^0(t)}{dt} = -110n^0(t) + 20$$



## نظریه‌ی تشدید و فقی

زیرسیستم گرادهند: مثال

### ORIENTING SUBSYSTEM EXAMPLE

$$\varepsilon = 0.1, \alpha = 3, \beta = 4 (\rho = 0.75)$$

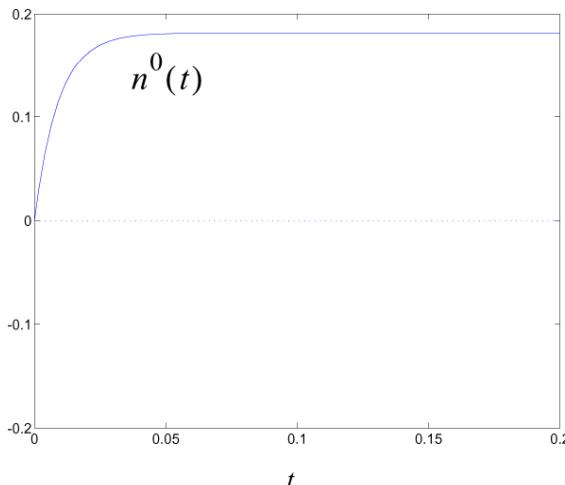
$$\mathbf{p} = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$$

$$\mathbf{a}^1 = \begin{bmatrix} 1 \\ 0 \end{bmatrix}$$

معادله‌ی عملیاتی:

$$(0.1) \frac{dn^0(t)}{dt} = -n^0(t) + (1 - n^0(t))\{3(p_1 + p_2)\} - (n^0(t) + 1)\{4(a_1^1 + a_2^1)\}$$

$$\frac{dn^0(t)}{dt} = -110n^0(t) + 20$$



در این مثال:  
اگر پارامتر هوشیاری برابر 0.25 بود هیچ بازنشانی رخ نمی‌داد، زیرا

$$\|\mathbf{a}^1\|^2/\|\mathbf{p}\|^2 = 1/2$$

سیگнал reset به لایه‌ی ۲ ارسال می‌شود،  
زیرا  $n^0(t)$  مثبت است.

در این مثال:  
از آنجا که پارامتر هوشیاری برابر 0.75 است و  $\mathbf{p}$  تنها دارای دو عضو است، reset، تنها در صورتی رخ می‌دهد که  $\mathbf{p}$  و  $\mathbf{a}^1$  یکسان نباشند.



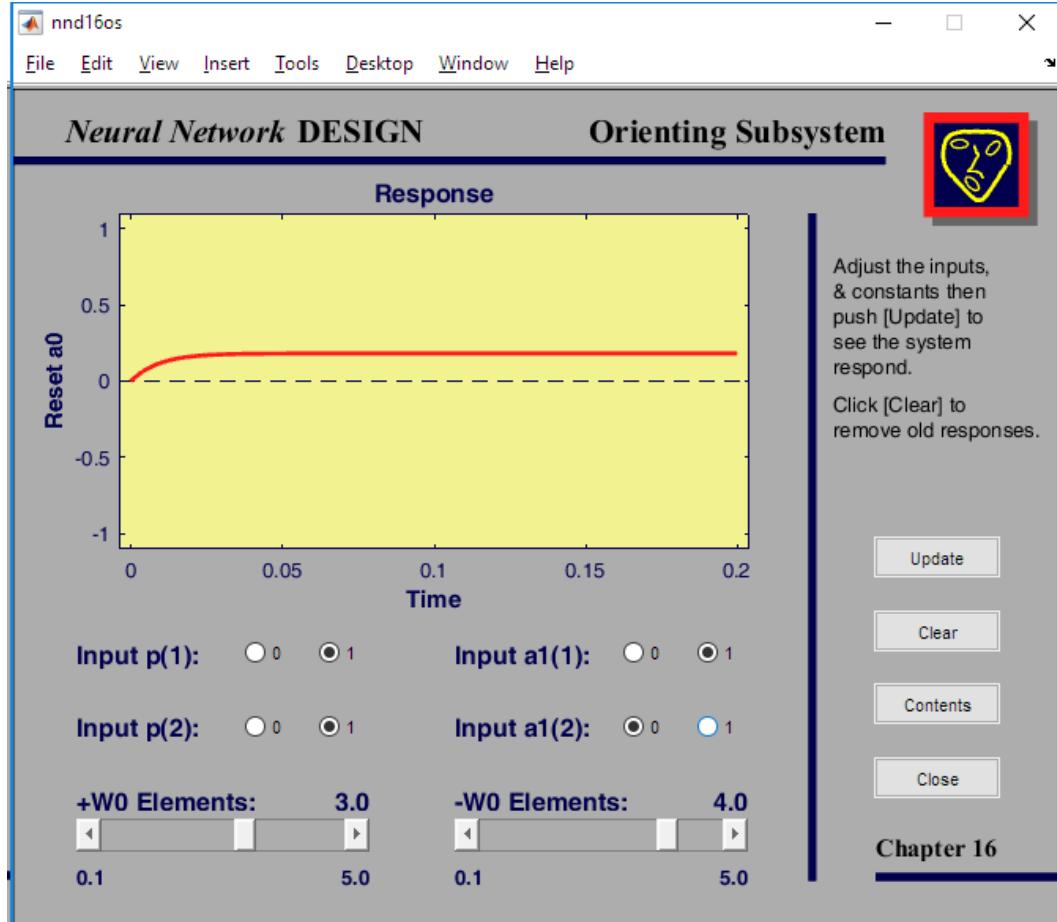
$$a^0 = \begin{cases} 1, & \text{if } [\|\mathbf{a}^1\|^2 / \|\mathbf{p}\|^2 < \rho] \\ 0, & \text{otherwise} \end{cases}$$

## نظریه‌ی تشذید و فقی

زیرسیستم گرادهند: خلاصه

ORIENTING SUBSYSTEM SUMMARY

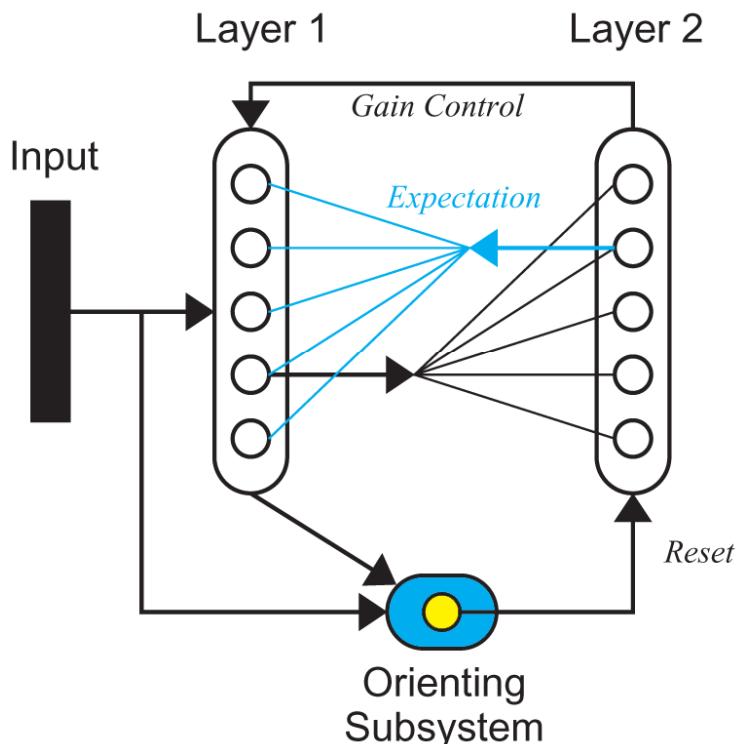
$$a^0 = \begin{cases} 1 , & \text{if } [\|\mathbf{a}^1\|^2 / \|\mathbf{p}\|^2 < \rho] \\ 0 , & \text{otherwise} \end{cases}$$



نظریه‌ی تشخیص و فقی

۵

# قوانین یادگیری



The ART1 network has two separate learning laws: one for the L1-L2 connections (instars) and one for the L2-L1 connections (outstars).

Both sets of connections are updated at the same time - when the input and the expectation have an adequate match.

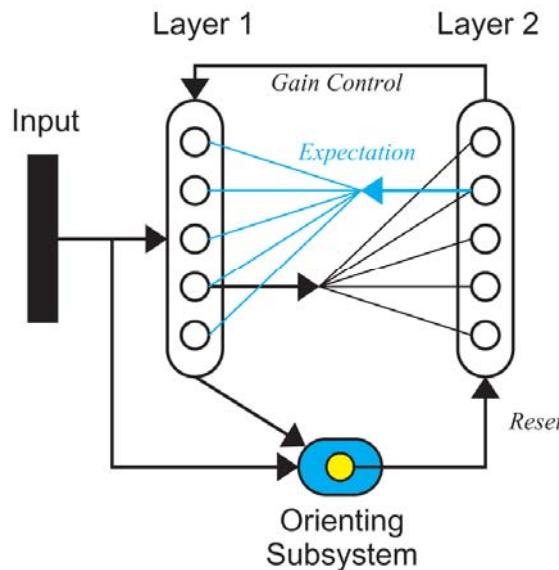
The process of matching, and subsequent adaptation is referred to as resonance.

## نظریه‌ی تشذید و فقی

قوانين یادگیری: L1-L2 و L2-L1

### LEARNING LAWS: L1-L2 AND L2-L1

شبکه‌ی ART1 دارای دو قاعده‌ی یادگیری مجزا است:  
یکی برای اتصالات L1-L2 و دیگری برای اتصالات L2-L1



برای یادگیری بازشناسی مجموعه‌ای از پروتوتایپ‌ها	L1-L2 یادگیری اتصالات (instars)
برای بازتولید (و به یادآوری) مجموعه‌ای از پروتوتایپ‌ها	L2-L1 یادگیری اتصالات (outstars)

Both sets of connections are updated at the same time - when the input and the expectation have an adequate match.

The process of matching, and subsequent adaptation is referred to as resonance.

هر دو مجموعه از اتصالات به طور همزمان به روزرسانی می‌شوند: وقتی ورودی و انتظار انطباق کافی دارند.  
(تعیین انطباق کافی با زیرسیستم گرادهند)

از فرآیند انطباق‌سنجی و وفق‌دهی پس از آن، تحت عنوان «رزونانس = تشذید» یاد می‌شود.

## نظریه‌ی تشدد و فقی

قوانين یادگیری: L1-L2 و L1-L1: معماه زیرمجموعه / ابرمجموعه

### SUBSET/SUPERSET DILEMMA

یادگیری اتصالات L1-L2 در شبکه‌ی ART1 بسیار شبیه به یادگیری در شبکه‌های گراسبرگ است.

**البته با یک تفاوت مهم:**

در شبکه‌ی گراسبرگ الگوهای ورودی در لایه‌ی ۱ نرمال می‌شوند

← همه‌ی الگوهای پروتوتایپ دارای طول یکسانی می‌باشند.

اما در شبکه‌ی ART1 هیچ عملیات نرمال‌سازی در لایه‌ی ۱ انجام نمی‌شود

← اگر یک الگوی پروتوتایپ زیرمجموعه‌ای از یک الگوی پروتوتایپ دیگر باشد، مشکل ایجاد می‌شود:

(معماه زیرمجموعه / ابرمجموعه)

# Subset/Superset Dilemma



Suppose that  $\mathbf{W}^{1:2} = \begin{bmatrix} 1 & 1 & 0 \\ 1 & 1 & 1 \end{bmatrix}$  so the prototypes are  ${}_1\mathbf{w}^{1:2} = \begin{bmatrix} 1 \\ 1 \\ 0 \end{bmatrix}$   ${}_2\mathbf{w}^{1:2} = \begin{bmatrix} 1 \\ 1 \\ 1 \end{bmatrix}$

We say that  ${}_1\mathbf{w}^{1:2}$  is a subset of  ${}_2\mathbf{w}^{1:2}$ , because  ${}_2\mathbf{w}^{1:2}$  has a 1 wherever  ${}_1\mathbf{w}^{1:2}$  has a 1.

If the output of layer 1 is  $\mathbf{a}^1 = \begin{bmatrix} 1 \\ 1 \\ 0 \end{bmatrix}$  then the input to Layer 2 will be

$$\mathbf{W}^{1:2}\mathbf{a}^1 = \begin{bmatrix} 1 & 1 & 0 \\ 1 & 1 & 1 \end{bmatrix} \begin{bmatrix} 1 \\ 1 \\ 0 \end{bmatrix} = \begin{bmatrix} 2 \\ 2 \end{bmatrix}$$

Both prototype vectors have the same inner product with  $\mathbf{a}^1$ , even though the first prototype is identical to  $\mathbf{a}^1$  and the second prototype is not. This is called the *Subset/Superset* dilemma.

## نظریه‌ی تشدید و فقی

قوانين یادگیری: L2-L1 و L1-L2: معنای زیرمجموعه/ابرمجموعه: مثال

### SUBSET/SUPERSET DILEMMA

Suppose that  $\mathbf{W}^{1:2} = \begin{bmatrix} 1 & 1 & 0 \\ 1 & 1 & 1 \end{bmatrix}$  so the prototypes are  ${}_1\mathbf{w}^{1:2} = \begin{bmatrix} 1 \\ 1 \\ 0 \end{bmatrix}$   ${}_2\mathbf{w}^{1:2} = \begin{bmatrix} 1 \\ 1 \\ 1 \end{bmatrix}$

We say that  ${}_1\mathbf{w}^{1:2}$  is a subset of  ${}_2\mathbf{w}^{1:2}$ , because  ${}_2\mathbf{w}^{1:2}$  has a 1 wherever  ${}_1\mathbf{w}^{1:2}$  has a 1.

If the output of layer 1 is  $\mathbf{a}^1 = \begin{bmatrix} 1 \\ 1 \\ 0 \end{bmatrix}$  then the input to Layer 2 will be

$$\mathbf{W}^{1:2}\mathbf{a}^1 = \begin{bmatrix} 1 & 1 & 0 \\ 1 & 1 & 1 \end{bmatrix} \begin{bmatrix} 1 \\ 1 \\ 0 \end{bmatrix} = \begin{bmatrix} 2 \\ 2 \end{bmatrix}$$

Both prototype vectors have the same inner product with  $\mathbf{a}^1$ , even though the first prototype is identical to  $\mathbf{a}^1$  and the second prototype is not. This is called the *Subset/Superset* dilemma.

هر دو بردار پروتوتایپ ضرب داخلی یکسانی با  $\mathbf{a}^1$  دارند، حتی اگر پروتوتایپ اول مساوی  $\mathbf{a}^1$  باشد و پروتوتایپ دوم نباشد.  
به این مشکل «معنای زیرمجموعه/ابرمجموعه» گفته می‌شود.

# Subset/Superset Solution



Normalize the prototype patterns.

$$\mathbf{W}^{1:2} = \begin{bmatrix} \frac{1}{2} & \frac{1}{2} & 0 \\ \frac{1}{2} & \frac{1}{2} & 0 \\ \frac{1}{3} & \frac{1}{3} & \frac{1}{3} \end{bmatrix}$$

$$\mathbf{W}^{1:2} \mathbf{a}^1 = \begin{bmatrix} \frac{1}{2} & \frac{1}{2} & 0 \\ \frac{1}{2} & \frac{1}{2} & 0 \\ \frac{1}{3} & \frac{1}{3} & \frac{1}{3} \end{bmatrix} \begin{bmatrix} 1 \\ 1 \\ 0 \end{bmatrix} = \begin{bmatrix} 1 \\ 2 \\ \frac{2}{3} \end{bmatrix}$$

Now we have the desired result; the first prototype has the largest inner product with the input.

## نظریه‌ی تشدید و فقی

قوانين یادگیری: L1-L2 و L1-L2: معماه زیرمجموعه/ابرمجموعه: راه حل

### SUBSET/SUPERSET SOLUTION

یک راه حل نرمال‌سازی بردارهای پروتوتایپ است:

Normalize the prototype patterns.

$$\mathbf{W}^{1:2} = \begin{bmatrix} 1 & 1 & 0 \\ \frac{1}{2} & \frac{1}{2} & 0 \\ \frac{1}{3} & \frac{1}{3} & 0 \\ \frac{1}{3} & \frac{1}{3} & 1 \end{bmatrix}$$

بنابراین، ورودی لایه‌ی ۲ به صورت زیر می‌شود:

$$\mathbf{W}^{1:2} \mathbf{a}^1 = \begin{bmatrix} 1 & 1 & 0 \\ \frac{1}{2} & \frac{1}{2} & 0 \\ \frac{1}{3} & \frac{1}{3} & 1 \end{bmatrix} \begin{bmatrix} 1 \\ 1 \\ 0 \end{bmatrix} = \begin{bmatrix} 1 \\ \frac{2}{3} \\ 0 \end{bmatrix}$$

Now we have the desired result; the first prototype has the largest inner product with the input.

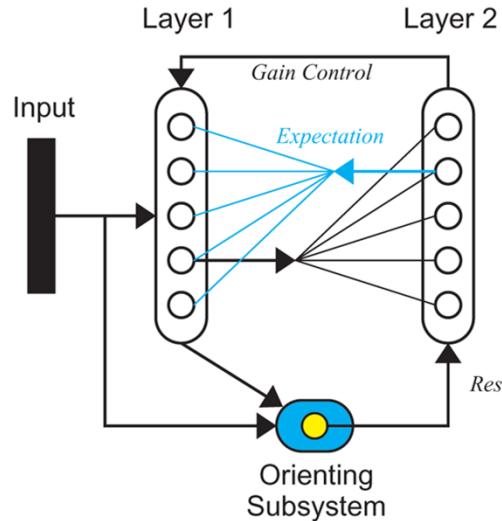
این بار نتیجه‌ی مطلوب حاصل شده است و بردار اولیه در ضرب داخلی با  $\mathbf{a}^1$  منجر به مقدار بزرگتری شده است، پس نرون اول از لایه‌ی ۲ فعال می‌شود.

## نظریه‌ی تشذید و فقی

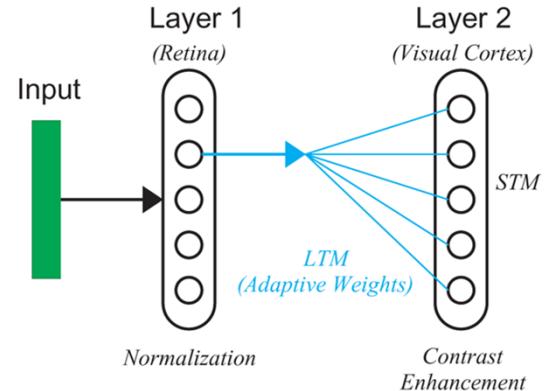
مقایسه‌ی نرمال‌سازی در شبکه‌های گراسبرگ و ART1

NORMALIZATION

## ART



## Grossberg



در شبکه‌ی ART1

عملیات نرمال‌سازی الگوهای پروتوتایپ،  
با استفاده از رقابت «مرکز-روشن/پیرامون-خاموش»  
در قانون یادگیری L1-L2 صورت می‌گیرد.

در شبکه‌ی گراسبرگ،

عملیات نرمال‌سازی الگوهای پروتوتایپ،  
با نرمال‌سازی الگوهای ورودی در لایه‌ی ۱ انجام می‌شود.

# L1-L2 Learning Law



## Instar Learning with Competition

$$\frac{d[{}_i\mathbf{w}^{1:2}(t)]}{dt} = a_i^2(t) [\{{}^+\mathbf{b} - {}_i\mathbf{w}^{1:2}(t)\} \zeta [{}^+\mathbf{W}] \mathbf{a}^1(t) - \{{}_i\mathbf{w}^{1:2}(t) + {}^-\mathbf{b}\} [{}^-\mathbf{W}] \mathbf{a}^1(t)],$$

where

$${}^+\mathbf{b} = \begin{bmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{bmatrix}$$



Upper Limit  
Bias

$${}^-\mathbf{b} = \begin{bmatrix} 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix}$$



Lower Limit  
Bias

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



On-Center  
Connections

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



Off-Surround  
Connections

When neuron  $i$  of Layer 2 is active,  ${}_i\mathbf{w}^{1:2}$  is moved in the direction of  $\mathbf{a}^1$ . The elements of  ${}_i\mathbf{w}^{1:2}$  compete, and therefore  ${}_i\mathbf{w}^{1:2}$  is normalized.

## نظریه‌ی تشذید و فقی

قانون یادگیری L1-L2

## L1-L2 LEARNING LAW

یادگیری Instar با رقابت

## Instar Learning with Competition

$$\frac{d[i\mathbf{w}^{1:2}(t)]}{dt} = a_i^2(t) [\{^+\mathbf{b} - i\mathbf{w}^{1:2}(t)\} \zeta [^+\mathbf{W}] \mathbf{a}^1(t) - \{i\mathbf{w}^{1:2}(t) + ^-\mathbf{b}\} [^-\mathbf{W}] \mathbf{a}^1(t)],$$

where

$${}^+\mathbf{b} = \begin{bmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{bmatrix} \quad {}^-\mathbf{b} = \begin{bmatrix} 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix}$$

Upper Limit Bias      Lower Limit Bias

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

On-Center Connections

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

Off-Surround Connections

این معادله بسیار شبیه به مدل شناختی با اتصالات درودی «مرکز-روشن / پردازون-خاموش» از  $\mathbf{b} = 0$  و  $\mathbf{W}^{1:2} = [0, 1]$  باشد، اطمینان حاصل می‌شود.

When neuron  $i$  of Layer 2 is active,  $i\mathbf{w}^{1:2}$  is moved in the direction of  $\mathbf{a}^1$ . The elements of  $i\mathbf{w}^{1:2}$  compete, and therefore  $i\mathbf{w}^{1:2}$  is normalized.

وقتی نرون  $i$  از لایه‌ی ۲ فعال باشد،  $i\mathbf{w}^{1:2}$  در جهت  $\mathbf{a}^1$  جابه‌جا می‌شود.  
عناصر  $i\mathbf{w}^{1:2}$  رقابت می‌کنند و در نتیجه  $i\mathbf{w}^{1:2}$  نرمال‌سازی می‌شود.





$$\frac{dw_{i,j}^{1:2}(t)}{dt} = a_i^2(t) \left[ (1 - w_{i,j}^{1:2}(t))\zeta a_j^1(t) - w_{i,j}^{1:2}(t) \sum_{k \neq j} a_k^1(t) \right]$$

For *fast learning* we assume that the outputs of Layer 1 and Layer 2 remain constant until the weights reach steady state.

Assume that  $a_i^2(t) = 1$ , and solve for the steady state weight:

$$0 = \left[ (1 - w_{i,j}^{1:2})\zeta a_j^1 - w_{i,j}^{1:2} \sum_{k \neq j} a_k^1 \right]$$

Case I:  $a_j^1 = 1$

$$0 = (1 - w_{i,j}^{1:2})\zeta - w_{i,j}^{1:2}(\|\mathbf{a}^1\|^2 - 1) = -(\zeta + \|\mathbf{a}^1\|^2 - 1)w_{i,j}^{1:2} + \zeta \quad \left. \right\} w_{i,j}^{1:2} = \frac{\zeta}{\zeta + \|\mathbf{a}^1\|^2 - 1}$$

Case II:  $a_j^1 = 0$

$$0 = -w_{i,j}^{1:2}\|\mathbf{a}^1\|^2 \quad \left. \right\} w_{i,j}^{1:2} = 0$$

Summary

$$_i \mathbf{w}^{1:2} = \frac{\zeta \mathbf{a}^1}{\zeta + \|\mathbf{a}^1\|^2 - 1}$$

## نظریه‌ی تشذید و فقی

قانون یادگیری L1-L2: یادگیری سریع

### FAST LEARNING

فرض می‌کنیم خروجی‌های لایه‌ی ۱ و ۲ تارسیدن وزن‌ها به حالت ماندگار، ثابت باقی می‌مانند  $\Leftarrow$  یادگیری سریع

$$\frac{dw_{i,j}^{1:2}(t)}{dt} = a_i^2(t) \left[ (1 - w_{i,j}^{1:2}(t))\zeta a_j^1(t) - w_{i,j}^{1:2}(t) \sum_{k \neq j} a_k^1(t) \right]$$

For *fast learning* we assume that the outputs of Layer 1 and Layer 2 remain constant until the weights reach steady state.

Assume that  $a_i^2(t) = 1$ , and solve for the steady state weight:

$$0 = \left[ (1 - w_{i,j}^{1:2})\zeta a_j^1 - w_{i,j}^{1:2} \sum_{k \neq j} a_k^1 \right] \quad \begin{array}{l} \text{با فرض فعال بودن} \\ \text{نرون } i \text{ در لایه‌ی ۲:} \end{array}$$

مشتق مساوی صفر در حالت ماندگار

Case I:  $a_j^1 = 1$

$$0 = (1 - w_{i,j}^{1:2})\zeta - w_{i,j}^{1:2}(\|\mathbf{a}^1\|^2 - 1) = -(\zeta + \|\mathbf{a}^1\|^2 - 1)w_{i,j}^{1:2} + \zeta \quad \left. \right\} w_{i,j}^{1:2} = \frac{\zeta}{\zeta + \|\mathbf{a}^1\|^2 - 1}$$

Case II:  $a_j^1 = 0$

$$0 = -w_{i,j}^{1:2}\|\mathbf{a}^1\|^2 \quad \left. \right\} w_{i,j}^{1:2} = 0$$

Summary

$$i\mathbf{w}^{1:2} = \frac{\zeta \mathbf{a}^1}{\zeta + \|\mathbf{a}^1\|^2 - 1}$$

۱ >  $\zeta$  می‌باشد تا اطمینان حاصل شود که مخرج کسر هرگز صفر نمی‌شود.  
 $\Leftarrow$  الگوهای پرتوتایپ نرمال\* می‌شوند (حل مشکل زیرمجموعه/ابرمجموعه)

\* آنچه که چکنی نسبت به سایرین ندارد. که اعضاً غیر صفر پیشتری دارند. اینجا مبنظر از نرمال بودن، داشتن اندازه‌ی [نیست،



## Outstar

$$\frac{d[\mathbf{w}_j^{2:1}(t)]}{dt} = a_j^2(t) [-\mathbf{w}_j^{2:1}(t) + \mathbf{a}^1(t)]$$

## Fast Learning

Assume that  $a_j^2(t) = 1$ , and solve for the steady state weight:

$$\mathbf{0} = -\mathbf{w}_j^{2:1} + \mathbf{a}^1 \quad \text{or} \quad \mathbf{w}_j^{2:1} = \mathbf{a}^1$$

Column  $j$  of  $\mathbf{W}^{2:1}$  converges to the output of Layer 1, which is a combination of the input pattern and the previous prototype pattern. The prototype pattern is modified to incorporate the current input pattern.

## نظریه‌ی تشدید و فقی

### قانون یادگیری L2-L1

#### LEARNING LAW: L2-L1

در معماری ART1، اتصالات L2-L1 با استفاده از قاعده‌ی یادگیری Outstar آموزش داده می‌شوند.

#### Outstar

$$\frac{d[\mathbf{w}_j^{2:1}(t)]}{dt} = a_j^2(t) [-\mathbf{w}_j^{2:1}(t) + \mathbf{a}^1(t)]$$

در صورتی که نرون زدر لایه‌ی ۲ فعال باشد (برنده‌ی رقابت)، آن‌گاه ستون زام  $\mathbf{W}^{2:1}$  به سمت الگوی  $\mathbf{a}^1$  حرکت می‌کند.

#### Fast Learning

با فرض سناریوی یادگیری سریع (ثابت ماندن خروجی لایه‌های ۱ و ۲ تا رسیدن وزن‌ها به حالت ماندگار):

Assume that  $a_j^2(t) = 1$ , and solve for the steady state weight:

فرض می‌کنیم که نرون زدر لایه‌ی ۲ فعال باشد، یعنی  $a_j^2 = 1$  و معادله را برابر وزن حالت ماندگار حل می‌کنیم:

$$\mathbf{0} = -\mathbf{w}_j^{2:1} + \mathbf{a}^1 \quad \text{or} \quad \mathbf{w}_j^{2:1} = \mathbf{a}^1$$

Column  $j$  of  $\mathbf{W}^{2:1}$  converges to the output of Layer 1, which is a combination of the input pattern and the previous prototype pattern. The prototype pattern is modified to incorporate the current input pattern.

پس ستون زام  $\mathbf{W}^{2:1}$  به سمت خروجی لایه‌ی ۱،  $\mathbf{a}^1$ ، همگرا می‌شود (که ترکیبی از الگوی ورودی و پروتوتاپ قبلی است). پس الگوی پروتوتاپ تغییر داده می‌شود تا الگوی ورودی جاری را دربرگیرد.

## نظریه‌ی تشدید و فقی

قانون یادگیری L2-L1

### LEARNING LAW: L2-L1

در معماری ART1، اتصالات L2-L1 با استفاده از قاعده‌ی یادگیری Outstar آموزش داده می‌شوند.

هدف از اتصالات L2-L1 به یادآوردن الگوهای پروتوتایپ مناسب (انتظارها) است.  
پس می‌توان این الگوهای پروتوتایپ را با الگوهای ورودی در لایه‌ی ۱ مقایسه و ترکیب نمود.

زمانی که انتظار و الگوی ورودی از انطباق کافی برخوردار نیستند،  
یک سیگنال reset به لایه‌ی ۲ ارسال می‌شود.  
← یک الگوی پروتوتایپ جدید قابلیت انتخاب شدن پیدا می‌کند.

\*  $W^{1:2}$  و  $W^{2:1}$  همزمان به روزرسانی می‌شوند:

وقتی نرون j-ام لایه‌ی ۲ فعال است و انطباق کافی بین انتظار و الگوی ورودی وجود دارد (شرط تشدید)،  
آن‌گاه سطر j-ام از  $W^{1:2}$  و ستون j-ام از  $W^{2:1}$  وفق داده می‌شوند (وفق دهی):

ستون j-ام از  $W^{2:1}$  مساوی  $a^1$  قرار داده می‌شود و به‌طور همزمان  
سطر j-ام از  $W^{1:2}$  برابر با نسخه‌ی نرمال‌شده‌ی  $a^1$  قرار داده می‌شود.

نظریه‌ی تشخیص و فقی

۶

خلاصه‌ی  
الگوریتم  
ART1

## نظریه‌ی تشدید و فقی

خلاصه‌ی الگوریتم ART1: مقداردهی آغازین

### ART1 ALGORITHM SUMMARY: INITIALIZATION

مقداردهی آغازین ماتریس‌های وزن:

اعضای ماتریس  $\mathbf{W}^{2:1}$  همگی برابر با 1 قرار داده می‌شوند.  
 $\downarrow$

اولین باری که یک نرون جدید از لایه‌ی 2 در رقابت برنده می‌شود، تشدید رخ می‌دهد،

$$\begin{aligned} \text{زیرا: } \mathbf{p}^1 &= \mathbf{p} \cap \mathbf{w}_j^{2:1} = \mathbf{p} \quad \text{و در نتیجه} \\ \|\mathbf{a}^1\|^2 / \|\mathbf{p}\|^2 &= 1 > \rho \end{aligned} \quad \downarrow$$

هر ستون آموزش ندیده در  $\mathbf{W}^{2:1}$  حالت خام دارد  
 و قابلیت وقیابی با هر یک از الگوهای ورودی را دارد.

از آنجا که سطرهای  $\mathbf{W}^{1:2}$  باید نسخه‌ی نرمال شده‌ی ستون‌های  $\mathbf{W}^{2:1}$  باشد،  
 برای عناصر آن قرار می‌دهیم:

$$\frac{\zeta}{\zeta + S^1 - 1}$$



- 0) All elements of the initial  $\mathbf{W}^{2:1}$  matrix are set to 1. All elements of the initial  $\mathbf{W}^{1:2}$  matrix are set to  $\zeta/(\zeta+S^1-1)$ .
- 1) Input pattern is presented. Since Layer 2 is not active,

$$\mathbf{a}^1 = \mathbf{p}$$

- 2) The input to Layer 2 is computed, and the neuron with the largest input is activated.

$$a_i^2 = \begin{cases} 1 , & \text{if } ((_i\mathbf{w}^{1:2})^T \mathbf{a}^1 = \max[(_k\mathbf{w}^{1:2})^T \mathbf{a}^1]) \\ 0 , & \text{otherwise} \end{cases}$$

In case of a tie, the neuron with the smallest index is the winner.

- 3) The L2-L1 expectation is computed.

$$\mathbf{W}^{2:1} \mathbf{a}^2 = \mathbf{w}_j^{2:1}$$

## نظریه‌ی تشید و فقی

خلاصه‌ی الگوریتم ART1 (۱ از ۲)

### ART1 ALGORITHM SUMMARY

- 0) All elements of the initial  $\mathbf{W}^{2:1}$  matrix are set to 1. All elements of the initial  $\mathbf{W}^{1:2}$  matrix are set to  $\zeta/(\zeta+S^l-1)$ .
- 1) Input pattern is presented. Since Layer 2 is not active,

$$\mathbf{a}^1 = \mathbf{p} \quad \text{: نمایش الگوی ورودی}$$

- 2) The input to Layer 2 is computed, and the neuron with the largest input is activated.

: محاسبه‌ی ورودی لایه‌ی ۲  
فعال شدن نرون  
دارای بزرگترین ورودی

$$a_i^2 = \begin{cases} 1 , & \text{if } ((_i\mathbf{w}^{1:2})^T \mathbf{a}^1 = \max[(_k\mathbf{w}^{1:2})^T \mathbf{a}^1]) \\ 0 , & \text{otherwise} \end{cases}$$

In case of a tie, the neuron with the smallest index is the winner.

در صورتی که ورودی‌ها مساوی بودند، نرون برنده آنی است که کوچکترین اندیس را دارد.

- 3) The L2-L1 expectation is computed.

محاسبه‌ی انتظار L2-L1 :

$$\mathbf{W}^{2:1} \mathbf{a}^2 = \mathbf{w}_j^{2:1}$$

# Summary Continued



- 4) Layer 1 output is adjusted to include the L2-L1 expectation.

$$\mathbf{a}^1 = \mathbf{p} \cap \mathbf{w}_j^{2:1}$$

- 5) The orienting subsystem determines match between the expectation and the input pattern.

$$a^0 = \begin{cases} 1, & \text{if } [\|\mathbf{a}^1\|^2 / \|\mathbf{p}\|^2 < \rho] \\ 0, & \text{otherwise} \end{cases}$$

- 6) If  $a^0 = 1$ , then set  $a_j^2 = 0$ , inhibit it until resonance, and return to Step 1. If  $a^0 = 0$ , then continue with Step 7.
- 7) Resonance has occurred. Update row  $j$  of  $\mathbf{W}^{1:2}$ .

$${}_j\mathbf{w}^{1:2} = \frac{\zeta \mathbf{a}^1}{\zeta + \|\mathbf{a}^1\|^2 - 1}$$

- 8) Update column  $j$  of  $\mathbf{W}^{2:1}$ .

$$\mathbf{w}_j^{2:1} = \mathbf{a}^1$$

- 9) Remove input, restore inhibited neurons, and return to Step 1.

## نظریه‌ی تشید و فقی

خلاصه‌ی الگوریتم ART1 (۲ از ۲)

### ART1 ALGORITHM SUMMARY

- 4) Layer 1 output is adjusted to include the L2-L1 expectation.

$$\mathbf{a}^1 = \mathbf{p} \cap \mathbf{w}_j^{2:1}$$

: تنظیم خروجی لایه‌ی ۱ برای وارد کردن انتظار

- 5) The orienting subsystem determines match between the expectation and the input pattern.

$$a^0 = \begin{cases} 1, & \text{if } \|\mathbf{a}^1\|^2 / \|\mathbf{p}\|^2 < \rho \\ 0, & \text{otherwise} \end{cases}$$

: تعیین میزان انطباق انتظار با الکوی ورودی  
توسط زیرسیستم گرادهندۀ

- 6) If  $a^0 = 1$ , then set  $a_j^2 = 0$ , inhibit it until resonance, and return to Step 1. If  $a^0 = 0$ , then continue with Step 7.  
انطباق کافی
- 7) Resonance has occurred. Update row  $j$  of  $\mathbf{W}^{1:2}$ .

$$j\mathbf{w}^{1:2} = \frac{\zeta \mathbf{a}^1}{\zeta + \|\mathbf{a}^1\|^2 - 1}$$

و قع تشید  
به هنگام سازی وزن‌ها

- 8) Update column  $j$  of  $\mathbf{W}^{2:1}$ .

$$\mathbf{w}_j^{2:1} = \mathbf{a}^1$$

اعمال الگوهای ورودی  
به شبکه  
تارسیدن به  
وزن‌های ماندگار

- 9) Remove input, restore inhibited neurons, and return to Step 1.

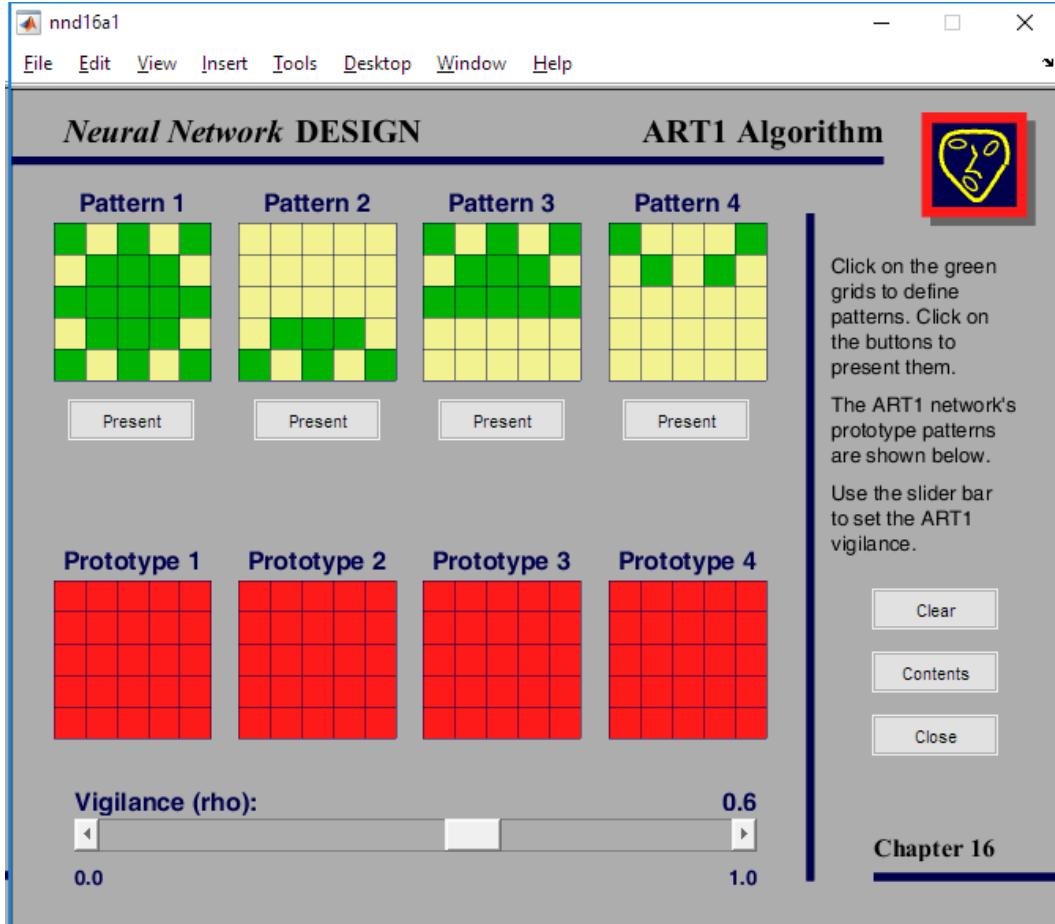
## نظریه‌ی تشدید و فقی

همگرایی الگوریتم ART1

ART1 ALGORITHM CONVERGENCE

کارپنتر و گراسبرگ ثابت کردند که

الگوریتم ART1 به ازای هر مجموعه از الگوهای ورودی خوش‌های پایدار تشکیل می‌دهد.



نظریه‌ی تشخیص و فقی

۷

دیگر  
معماری‌های  
ART

## دیگر معماری‌های ART

### OTHER ART ARCHITECTURES

یک محدودیت ART1: فقط بر روی الگوهای ورودی دودویی قابل تعریف است.

ART1 تنها یکی از مثال‌های نظریه‌ی تشذید ورقی است.  
کارپنتر، گراسبرگ و افراد دیگر، شکل‌های گوناگون دیگری از شبکه‌ی ART را پیشنهاد داده‌اند.

#### شبکه‌ی ART2

*ART2 Network*

#### شبکه‌ی ART3

*ART3 Network*

#### شبکه‌ی ARTMAP

*ARTMAP Network*

#### شبکه‌ی ARTMAP فازی

*Fuzzy ARTMAP Network*

## دیگر معماری‌های ART

شبکه‌ی ART2

### OTHER ART ARCHITECTURES

[کارپنتر و گراسبرگ]

شبکه‌ی ART2  
*ART2 Network*

برای استفاده در مورد الگوهای دودویی و آنالوگ

اصول ساختاری ART2 بسیار مشابه ART1 است.

تفاوت:

لایه‌ی ۱ شبکه‌ی ART2 دارای چندین زیرلایه است.

(زیرا بردارهای آنالوگ برخلاف بردارهای دودویی تا هر اندازه‌ای می‌توانند به هم نزدیک باشند؛ وجود این زیرلایه‌ها ضروری است زیرا این زیرلایه‌ها ترکیبی از اعمال نرم‌السازی و حذف نویز را علاوه بر مقایسه‌ی بردار ورودی و انتظار انجام می‌دهند.)

## دیگر معماری‌های ART

شبکه‌ی ART3

### OTHER ART ARCHITECTURES

[کارپتر و گراسبرگ]

شبکه‌ی ART3  
*ART3 Network*

دارای مکانیسم بازنشانی (reset) پیچیده‌تر [نزدیک‌تر به مدل‌های بیولوژیکی]

## دیگر معماری‌های ART

### شبکه‌ی ARTMAP

#### OTHER ART ARCHITECTURES

[کارپنتر، گراسبرگ و رینولدز]

شبکه‌ی ARTMAP  
ARTMAP Network

یک شبکه‌ی بانظارت (برخلاف انواع دیگر ART)

شامل دو مازول ART که توسط یک حافظه‌ی انجمنی inter-ART به هم متصل شده‌اند.

یک مازول ART: برای دریافت بردار ورودی (input)

یک مازول ART دیگر: برای دریافت بردار خروجی مطلوب (target)

شبکه یاد می‌گیرد با ارائه‌ی یک بردار ورودی به آن، بردار خروجی صحیح را پیش‌بینی کند.

## دیگر معماری‌های ART

شبکه‌ی ARTMAP فازی

### OTHER ART ARCHITECTURES

شبکه‌ی ARTMAP فازی  
*Fuzzy ARTMAP Network*

[کارپتر، گراسبرگ، مارکوزن، رینولدز و روزن]

استفاده از منطق فازی در ساختار شبکه‌ی ART

افزایش کارآیی به شکل قابل توجه  
به خصوص در مورد الگوهای ورودی دارای نویز

## دیگر معماری‌های ART

### مشترکات

#### OTHER ART ARCHITECTURES

همهی معماری‌های مختلف ART ماثول‌های کلیدی ART1 را دارند، از جمله:

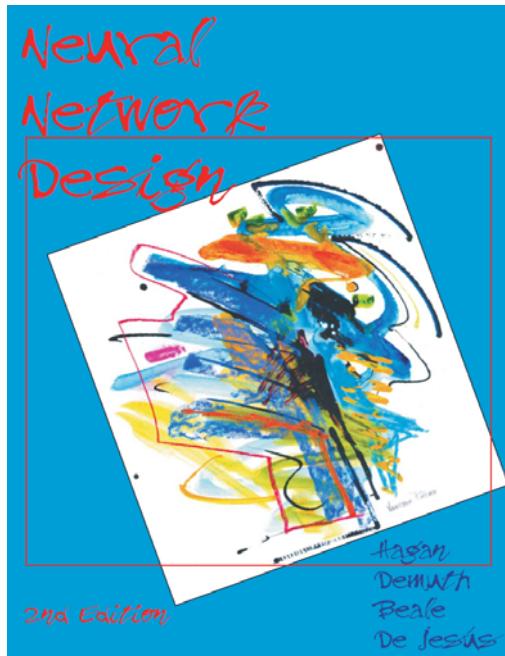
- قاعده‌ی **Instar** در اتصالات L1-L2 برای **بازشناسی الگوها**
- قاعده‌ی **Outstar** در اتصالات L2-L1 برای **بیادآوری الگوها**
- لایه‌ی ۲ با هدف **ارتقای کنتراست** (رقابت)
- لایه‌ی ۱ با هدف **مقایسه‌ی الگوهای «ورودی» و «انتظار»**
- زیرسیستم گرادهنده برای **بازنشانی** در هنگام عدم تطابق الگوها

نظریه‌ی تشخیص و فقی



# منابع

## منبع اصلی



Martin T. Hagan, Howard B. Demuth, Mark H. Beale, Orlando De Jesus,  
**Neural Network Design**,  
 2<sup>nd</sup> Edition, Martin Hagan, 2014.  
**Chapter 19**

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

## 19 Adaptive Resonance Theory

Objectives	19-1
Theory and Examples	19-2
Overview of Adaptive Resonance	19-2
Layer 1	19-4
Steady State Analysis	19-6
Layer 2	19-10
Orienting Subsystem	19-13
Learning Law: L1-L2	19-16
Subset/Superset Dilemma	19-17
Learning Law	19-18
Learning Law: L2-L1	19-20
ART1 Algorithm Summary	19-21
Initialization	19-21
Algorithm	19-21
Other ART Architectures	19-23
Summary of Results	19-24
Solved Problems	19-29
Epilogue	19-44
Further Reading	19-45
Exercises	19-47

### Objectives

In Chapter 18 and Chapter 19 we learned that one key problem of competitive networks is the stability of learning. There is no guarantee that, as more inputs are applied to the network, the weight matrix will eventually converge. In this chapter we will present a modified type of competitive learning, called adaptive resonance theory (ART), which is designed to overcome the problem of learning stability.

19.1