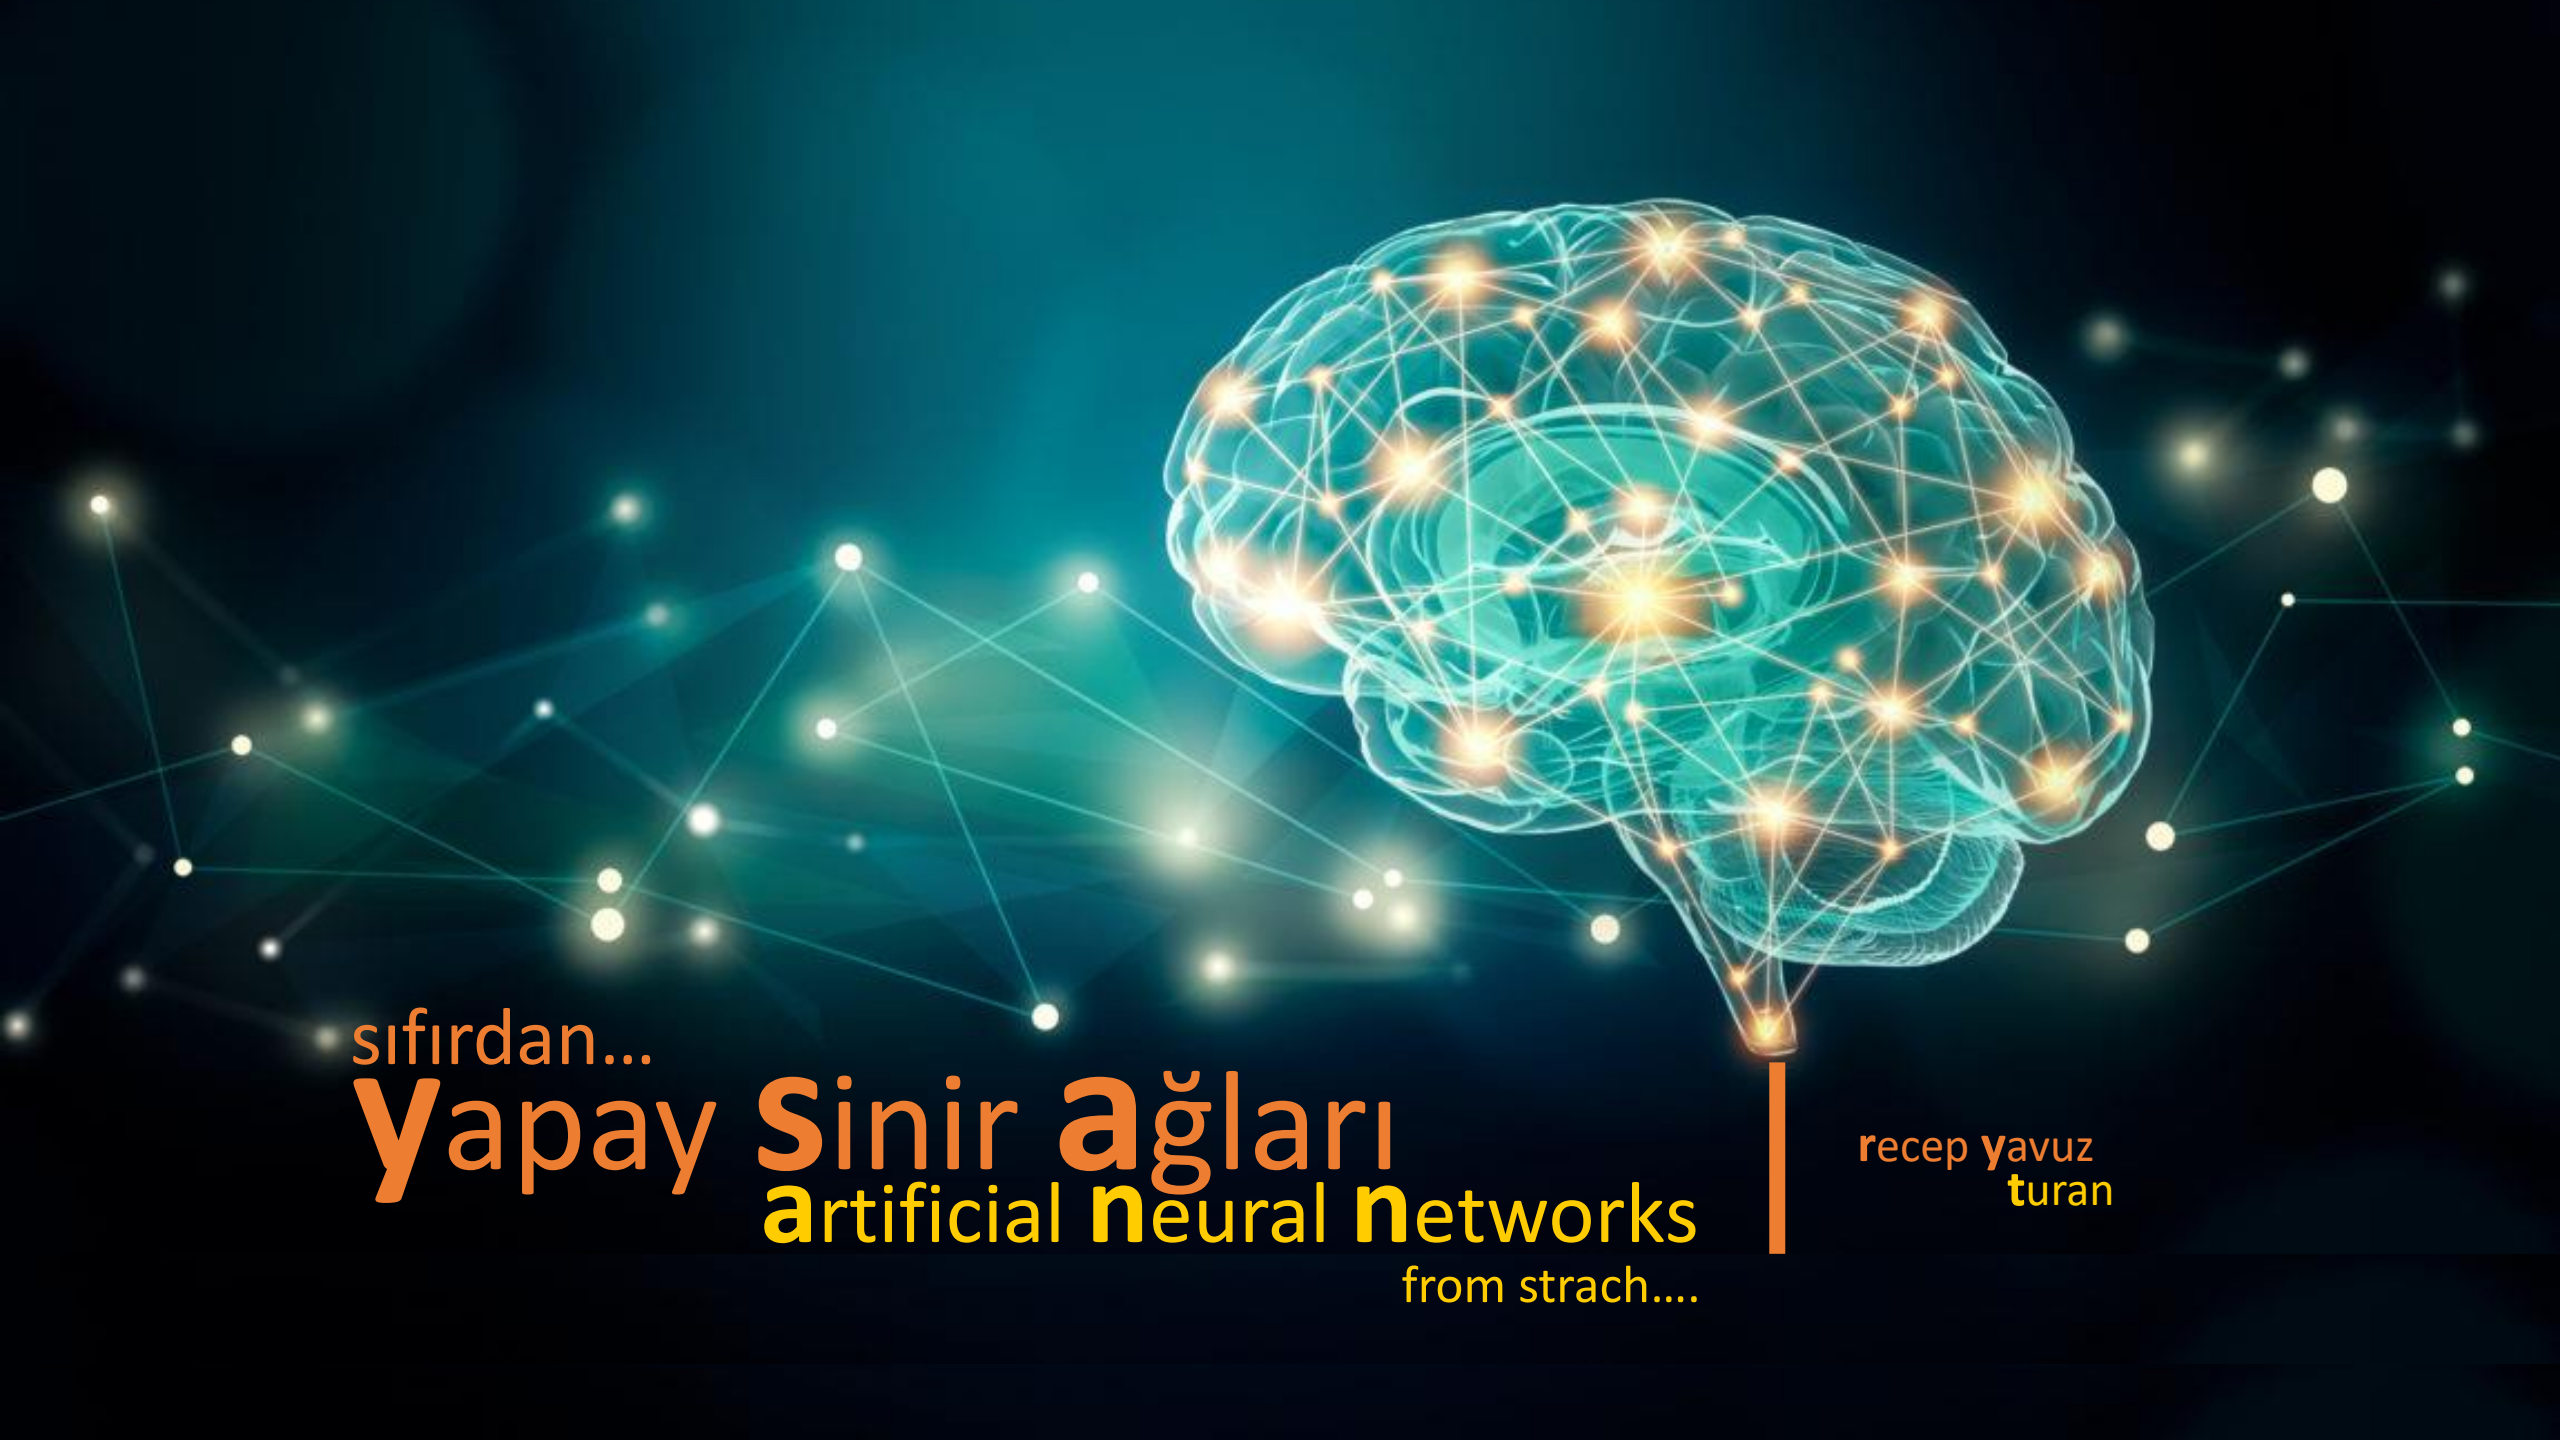
sıfırdan...
Yapay Sinir ağları
artificial neural networks
from strach....
recep yavuz
turan

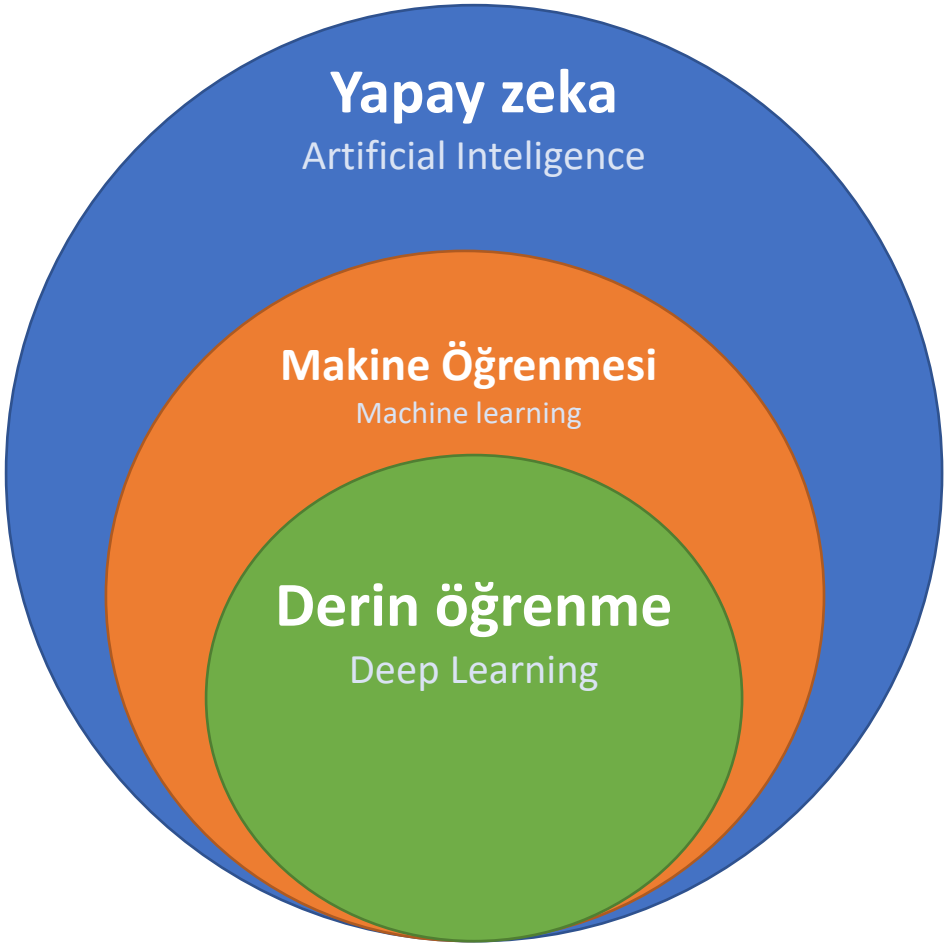

Özel Yapay zeka Artifical Narrow İnteligence

İnsan zekâsından zayıf

Günümüz

Genel Yapay Zeka Artificial Genral Inteligence

İnsan zekâsına eşit

2040

Süper yapay zeka Artificial Super Inteligence

İnsan zekâsndan çok daha gelişmiş

2060

Basit yapay sinir ağı
Simple Artificial Neural Network

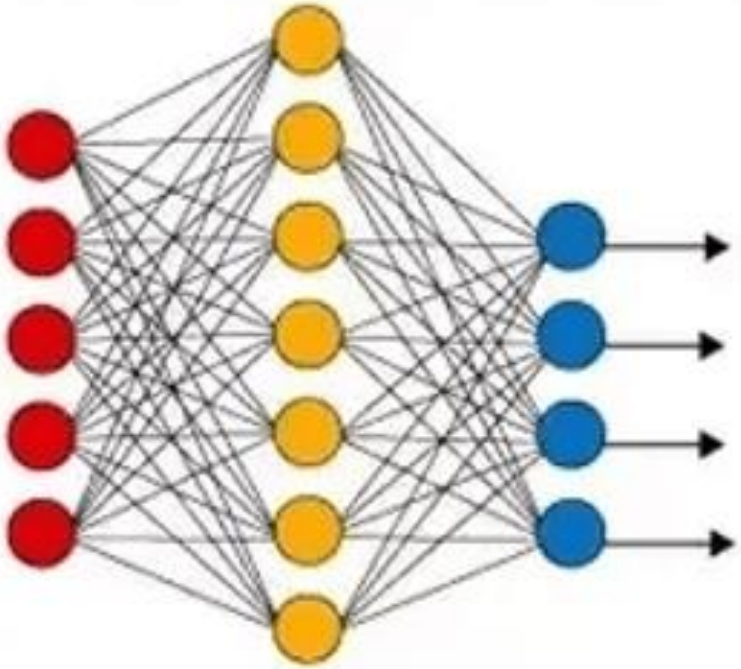

Derin öğrenme sinir ağı
Deep Learning Neural Network

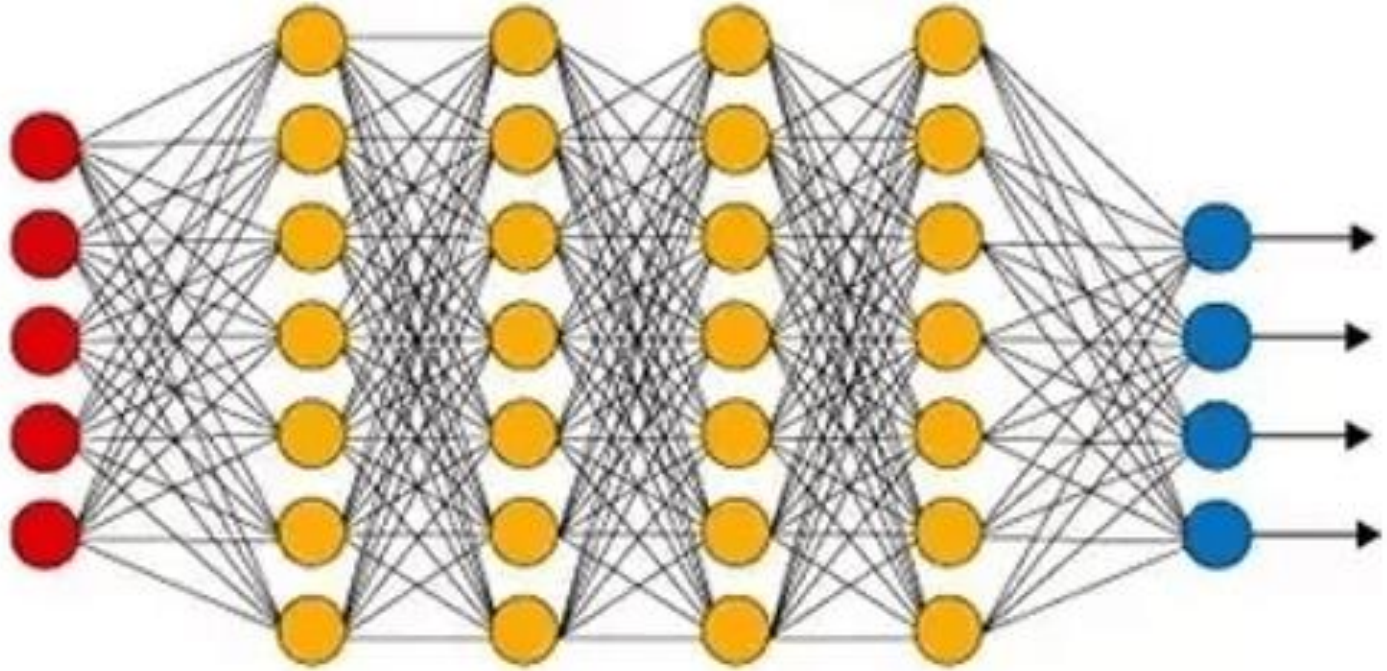

Giriş nöronları
Input Neurons

Gizli nöronlar
Hidden Neurons

Çıkış nöronları
Output Neurons

Yönlü bir graf oluşturacak şekilde yapay nöronların düzenlenmesiyle oluşur….

Sınıflandırma, tahmin gibi işlemleri öğrenip uygulamak için tasarlanan makine öğrenmesi sistemleridir.

Beyinde bulunan biyolojik nöronlardan esinlenilmiştir.

Kontrol, örüntü tanıma, finans, tıp, veri madenciliği, sıralı işlem tanıma, jeolojik bilimler gibi bir çok alanda kullanılmaktadır.

özet

ysa gelişimi progress of ann

brief history

1938

Nicolas **Rashevsky**

- Nöral Alan teorisi
- Sinir ağlarındaki yayılım ve aktivasyonu diferansiyel denklemlerle ifade etmiştir.

1943

Walter **Pitts ve** Warren Sturgis **McCulloch**

- Basit eşik fonksiyonlarla biyolojik nöronlara benzer yapay modeli sunmuşlardır.

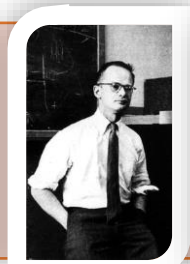

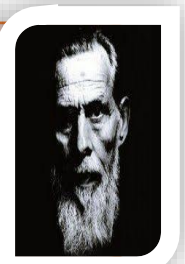

1949

Donald Olding **Hebb**

- The Organization of Behavior
- Pavlov'un klasik koşullanmasına dayanan öğrenme teorisini sunmuştur:
  «Belirli bir snaps üzerinden sürekli tekrar eden tetiklenme nöronun iletkenliğini arttırır.»

1954

Denis **Gabor**

• Gözlenen çıkış işareti ile geçmiş bilgiye dayanarak üretilen işaretin ortalama karesel hatalarını minimize eden optimum ağırlıkları dereceli azalma yöntemiyle tespit eden bir öğrenme filtresi geliştirmiştir.

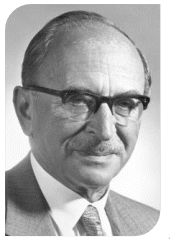

1958

Frank **Rosenblatt**

• McCulloch ve Pitts nöron modelini kullanarak bir öğrenme metodu geliştirmiştir.
• «Perceptron»un mucidir.

1960

Bernard **Widrow** ve Marcian Edward "Ted" **Hoff** Jr.

• **Adaline** –(Adaptive Linear Neuron /Adaptive Linear Element)
• Dereceli azalma yöntemiyle ortalama karesel hataları minimize ederek öğrenen bir ağ geliştirmişlerdir.

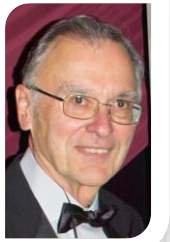

1969

Marvin **Minsky** ve Seymour **Papert**

- «Perceptrons» kitabı
- Temel perceptronların sınırlarını hesaplama kabiliyetlerinin kötülüğünü göstermişlerdir.


1982

John **Hopfield**

- İlişkisel hafıza olarak kullanılabilecek bir tekrarlayan sinir ağını istatistiksel yöntemlerle açıklamıştır.

1986

David Everett **Rumelhart** ve James Lloyd "Jay" **McClelland**

- Çok katmanlı ağların Geri yayılım yöntemiyle öğrenmesi Minsky ve Papert tarafından eleştirilere cevap olmuştur.



Yapay Nöronartificial neuron

YSA'lar biyolojik nöronlardan esinlenerek yapılmışlardır. Ancak özellikle belirtmek gerekir ki beynin birebir kopyasını oluşturmak gibi bir amaç taşımazlar.

İnsan Beyninin 100 000 000 000 nörondan ve 100 000 000 000 000 sinaps(nöronlar arasındaki bağlantı) oluştuğu belirtilmektedir.

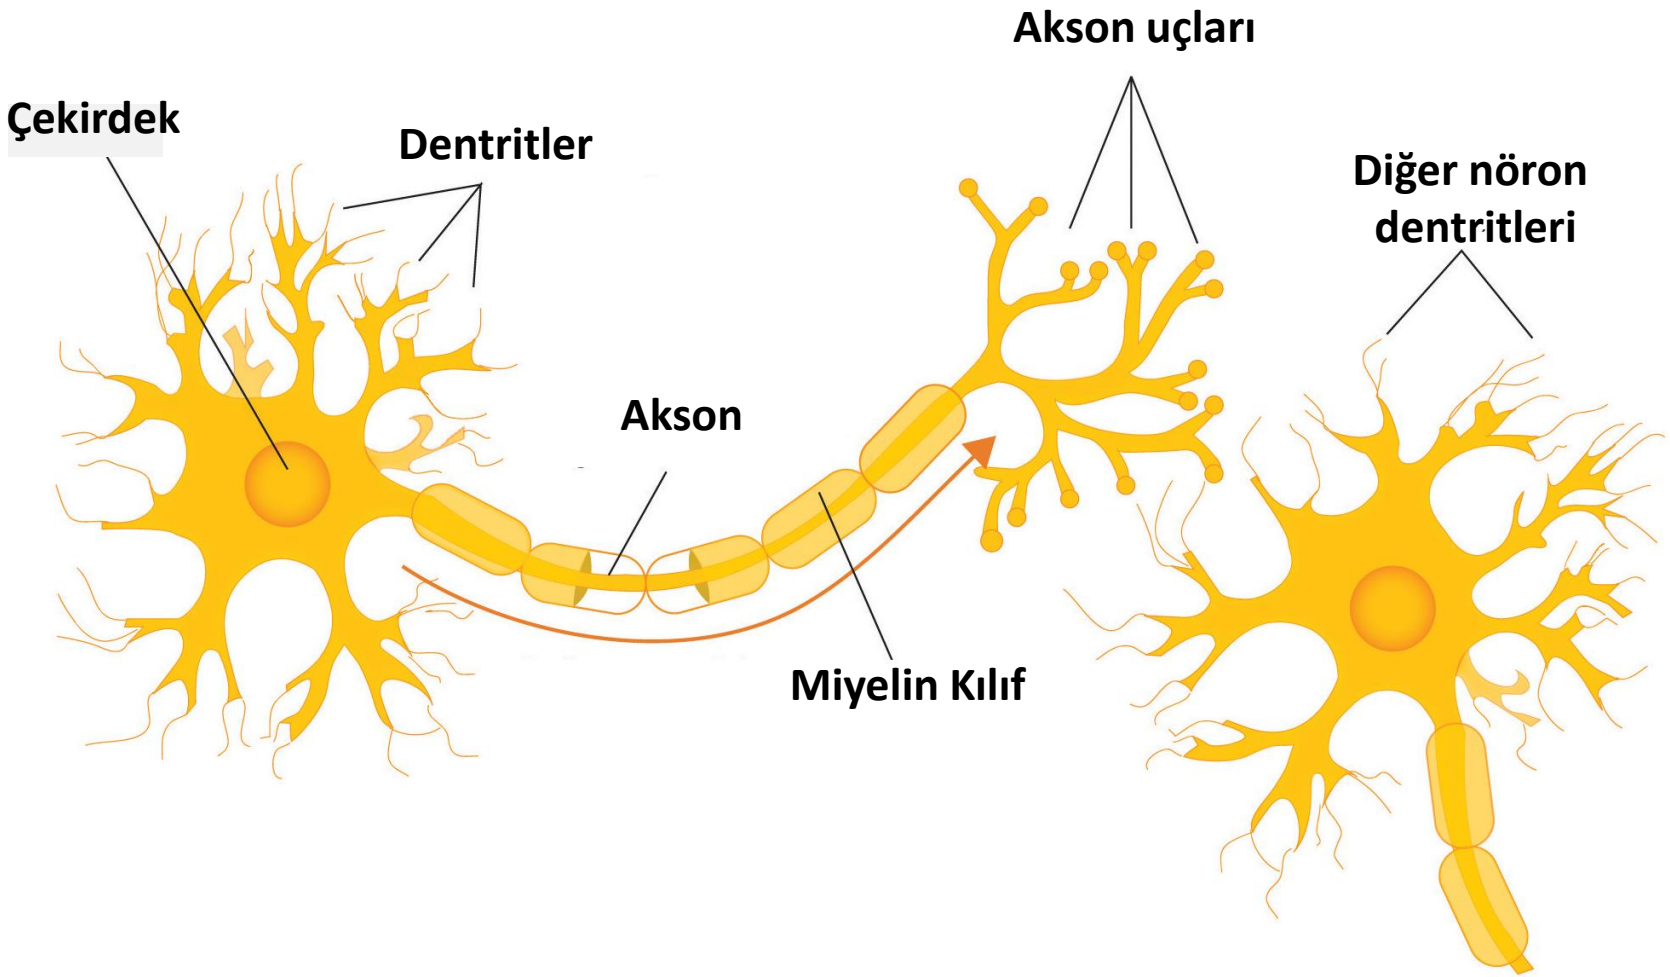
Akson uçları
Çekirdek
Dentritler
Diğer nöron
dentritleri
Akson
Miyelin Kılıf

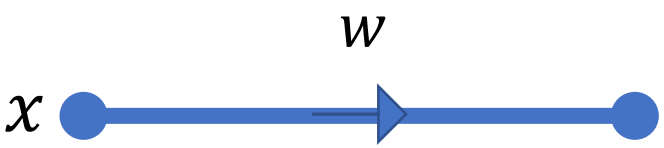

$$y = x\,w$$

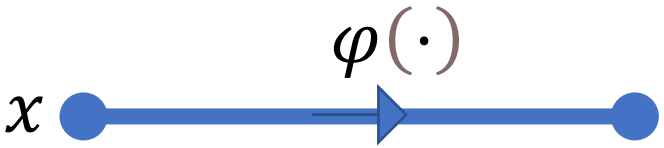

$$y = \varphi(x)$$

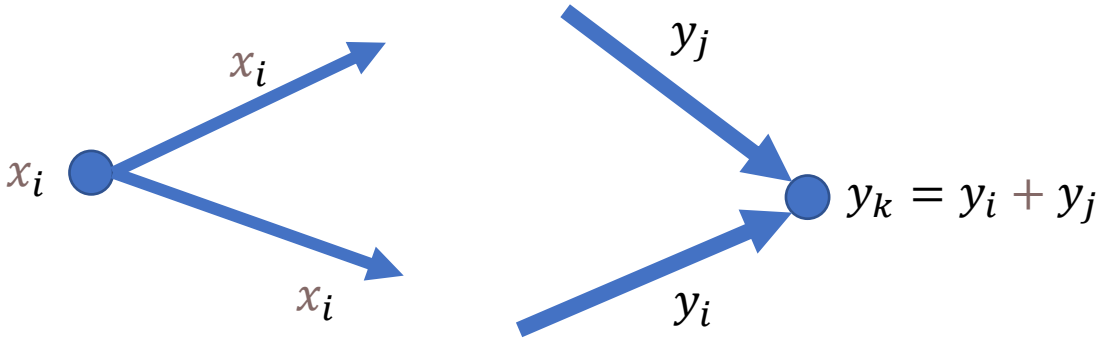

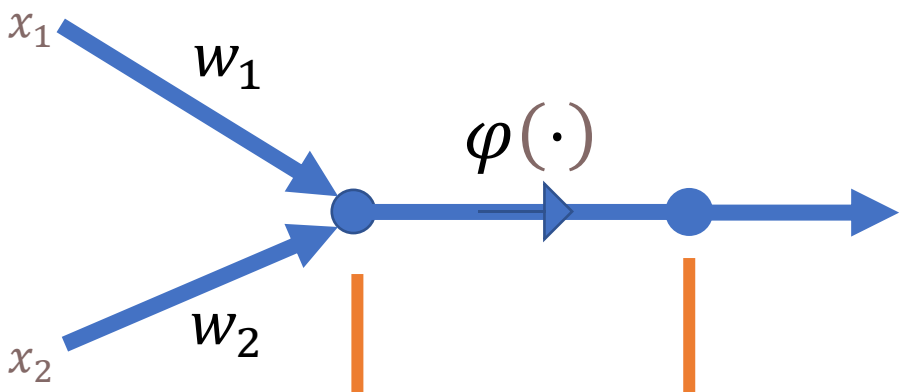

$$x_1 w_1 + x_2 w_2 \qquad \varphi(x_1 w_1 + x_2 w_2)$$

$$\sum_{i=1}^{n} x_i w_i \qquad \varphi\left(\sum_{i=1}^{n} x_i w_i\right)$$

$$\sum_{i=1}^{n} x_i w_i$$

```
toplam=0
i=1
i n den küçük oldukça
        toplam=toplam+ xi*wi
sonraki i
```

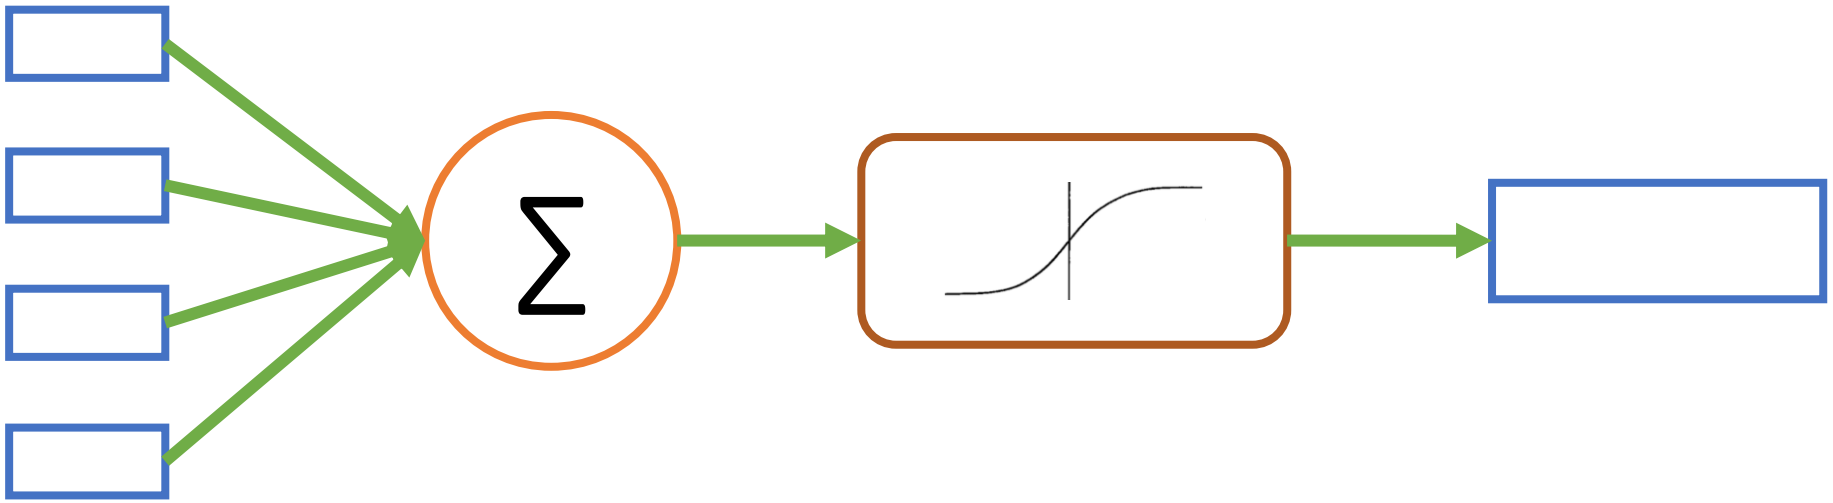
Σ

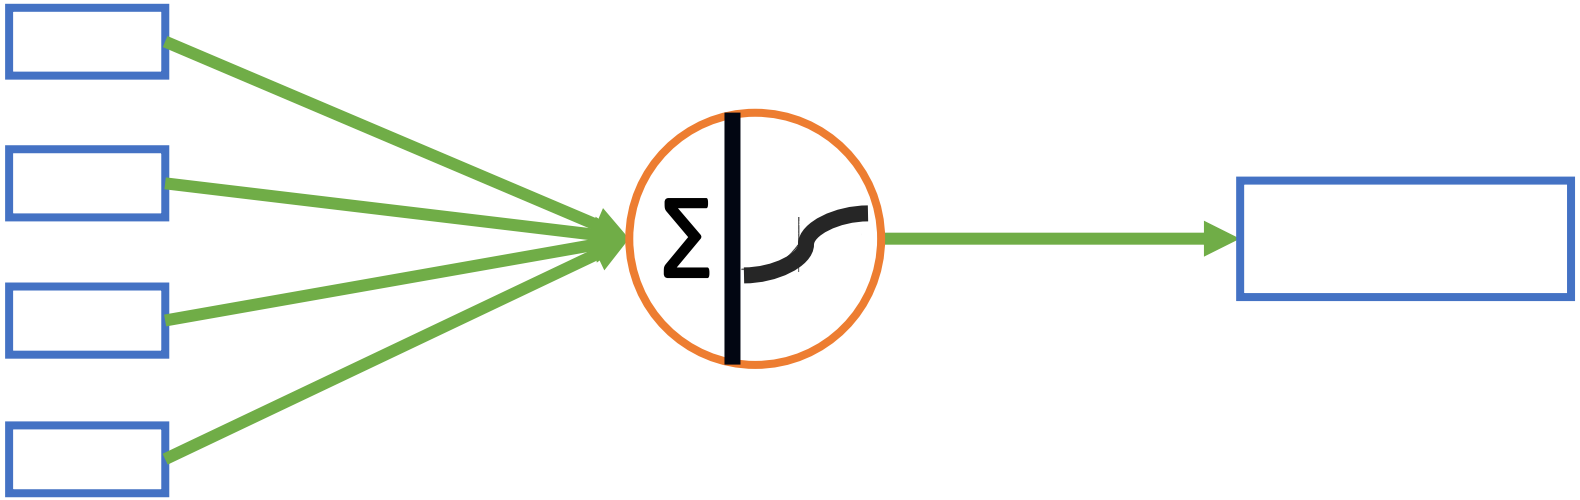
Σ

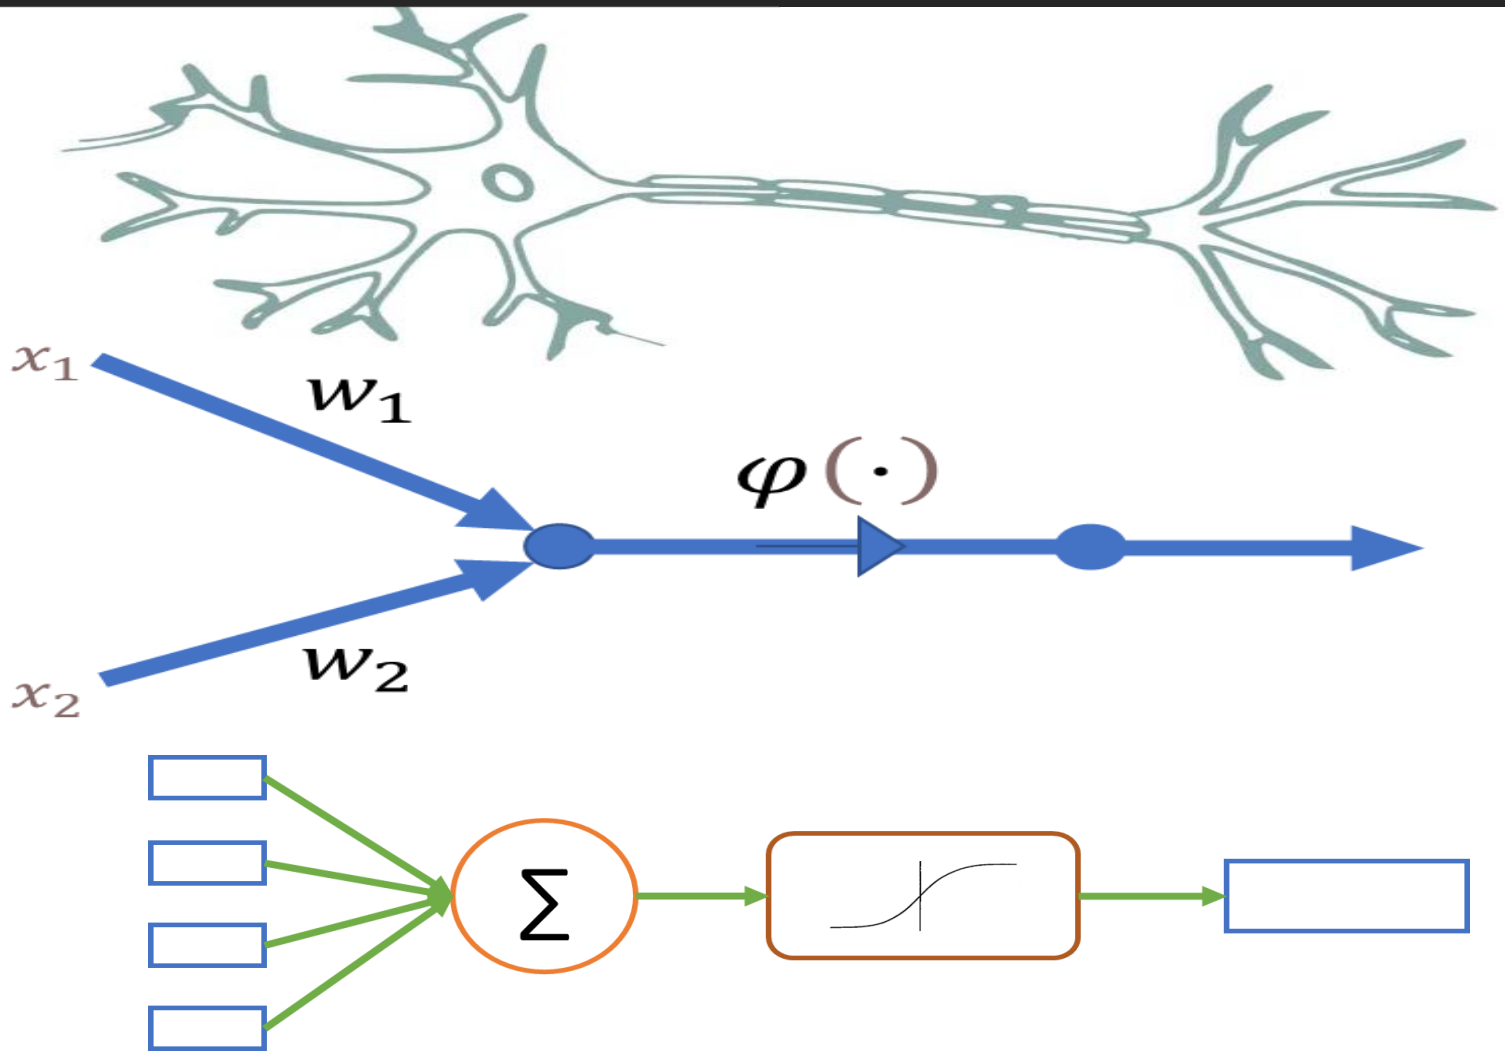
x_1
w_1
$\varphi(\cdot)$
x_2
w_2
Σ

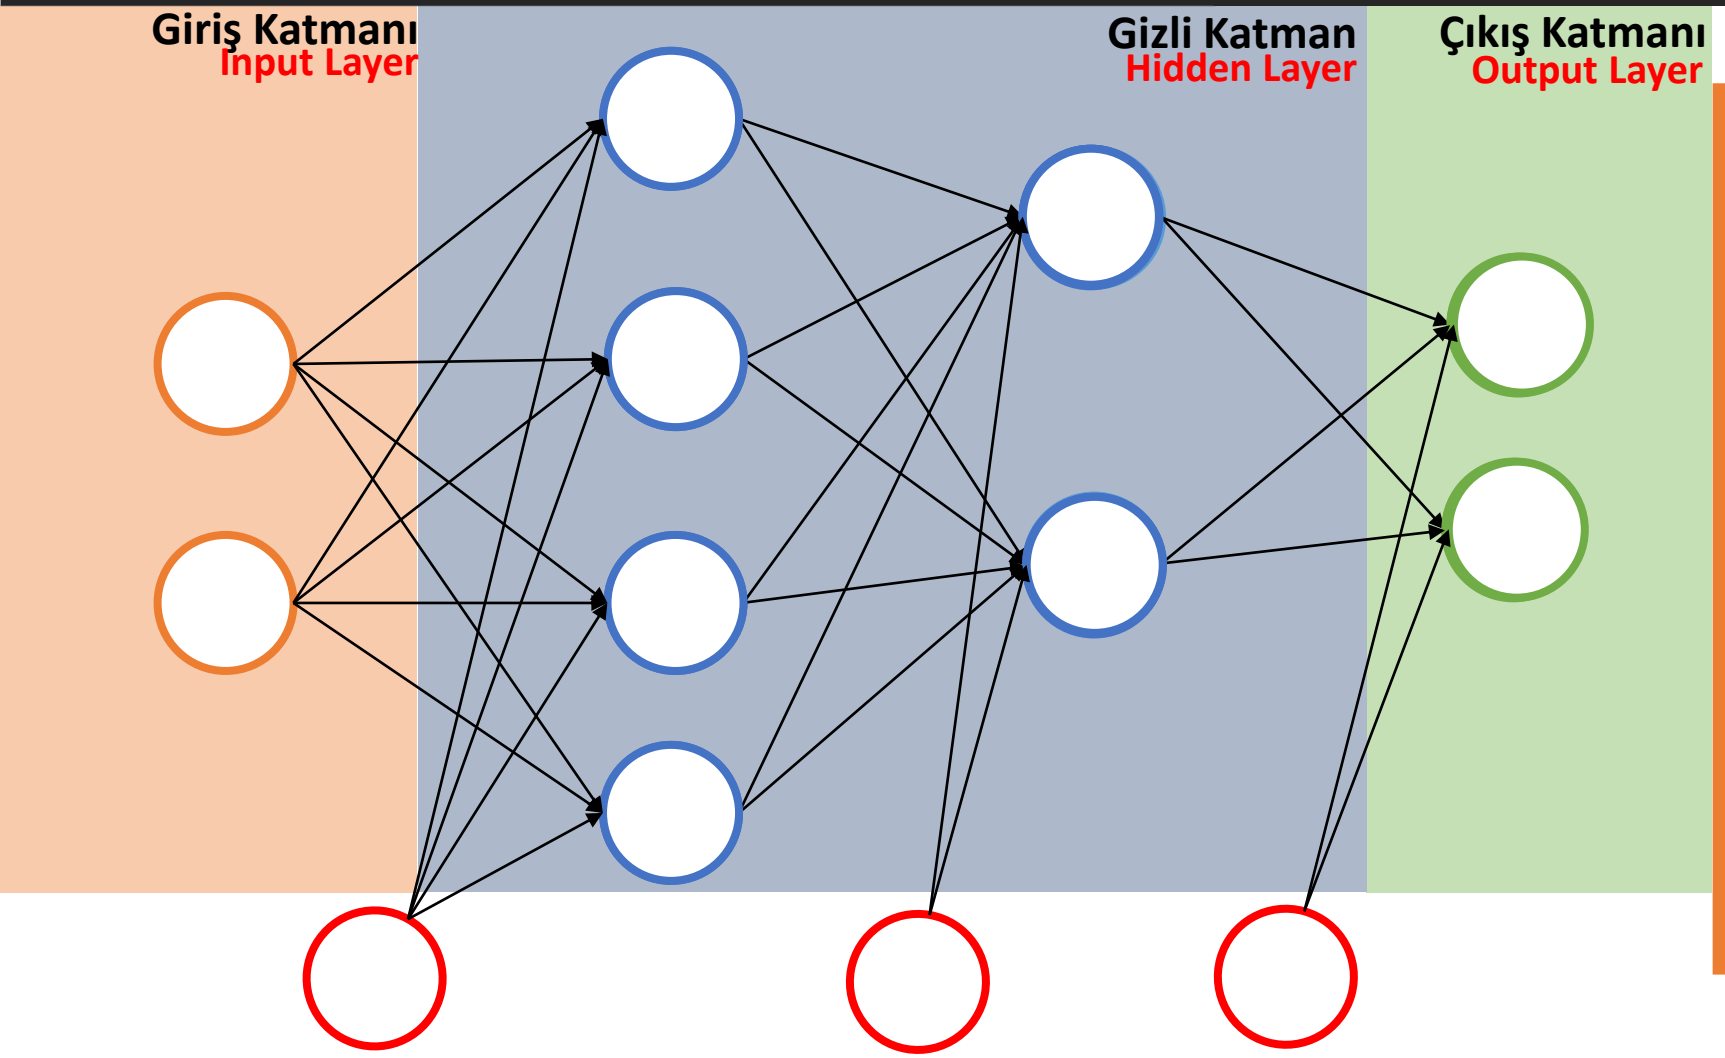

Giriş nöronları
Input neurons

Çıkış nöronları
Output neurons

Gizli nöronlar
Hidden neurons

Bias nöronları
Bias neurons

nöron tipleri ? | yapay nöron ?

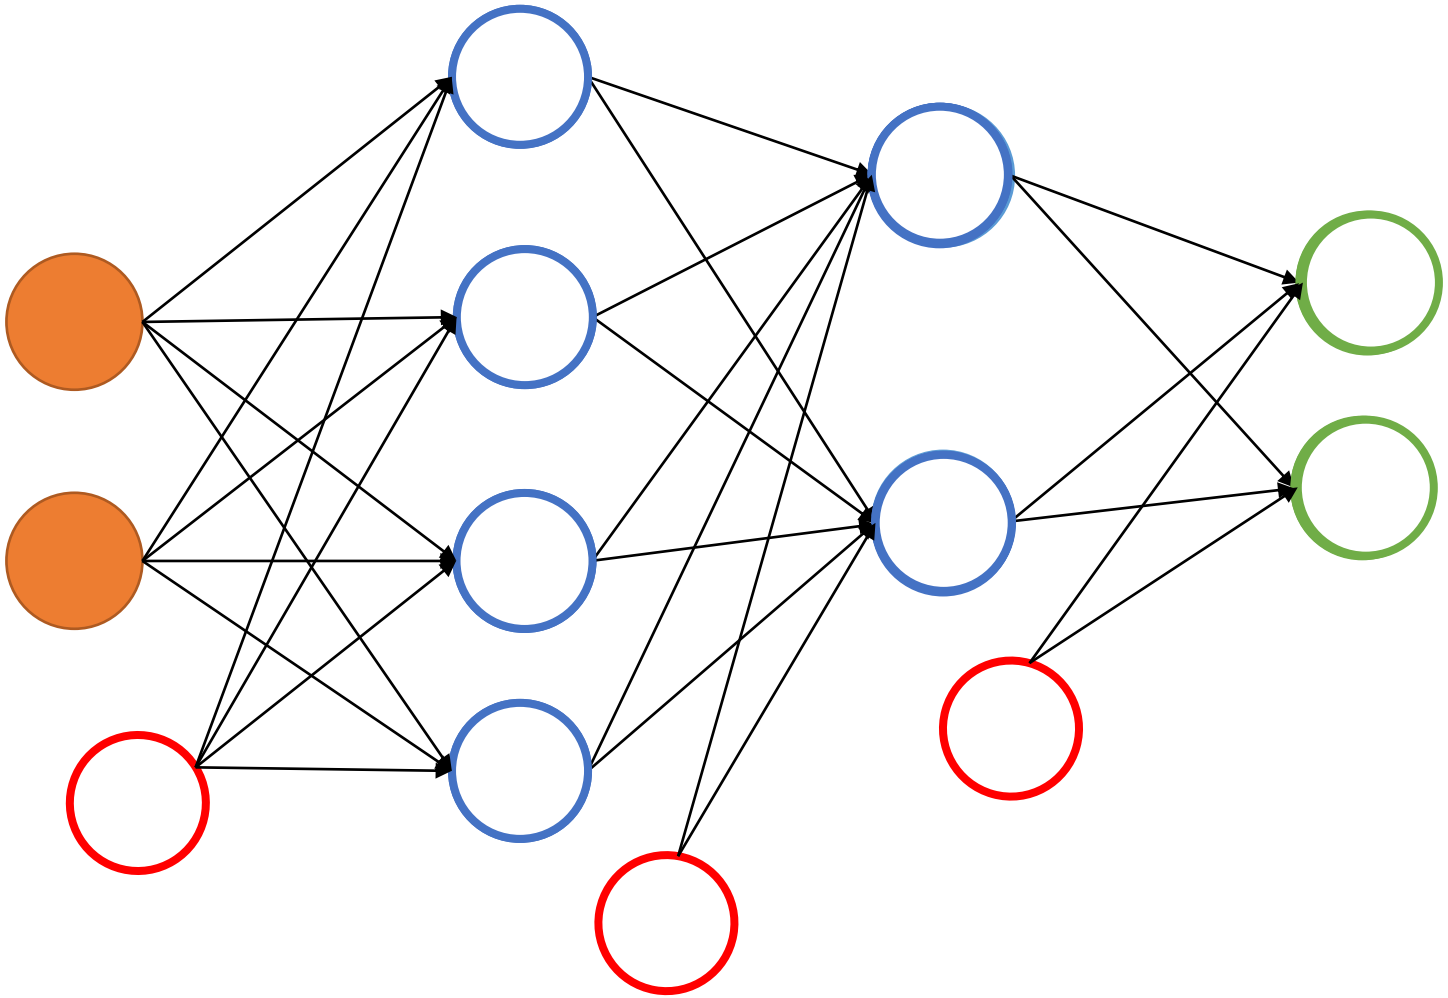

Giriş nöronları

Input neurons

Ağa başlangıç bilgisinin gönderildiği nöronlardır.

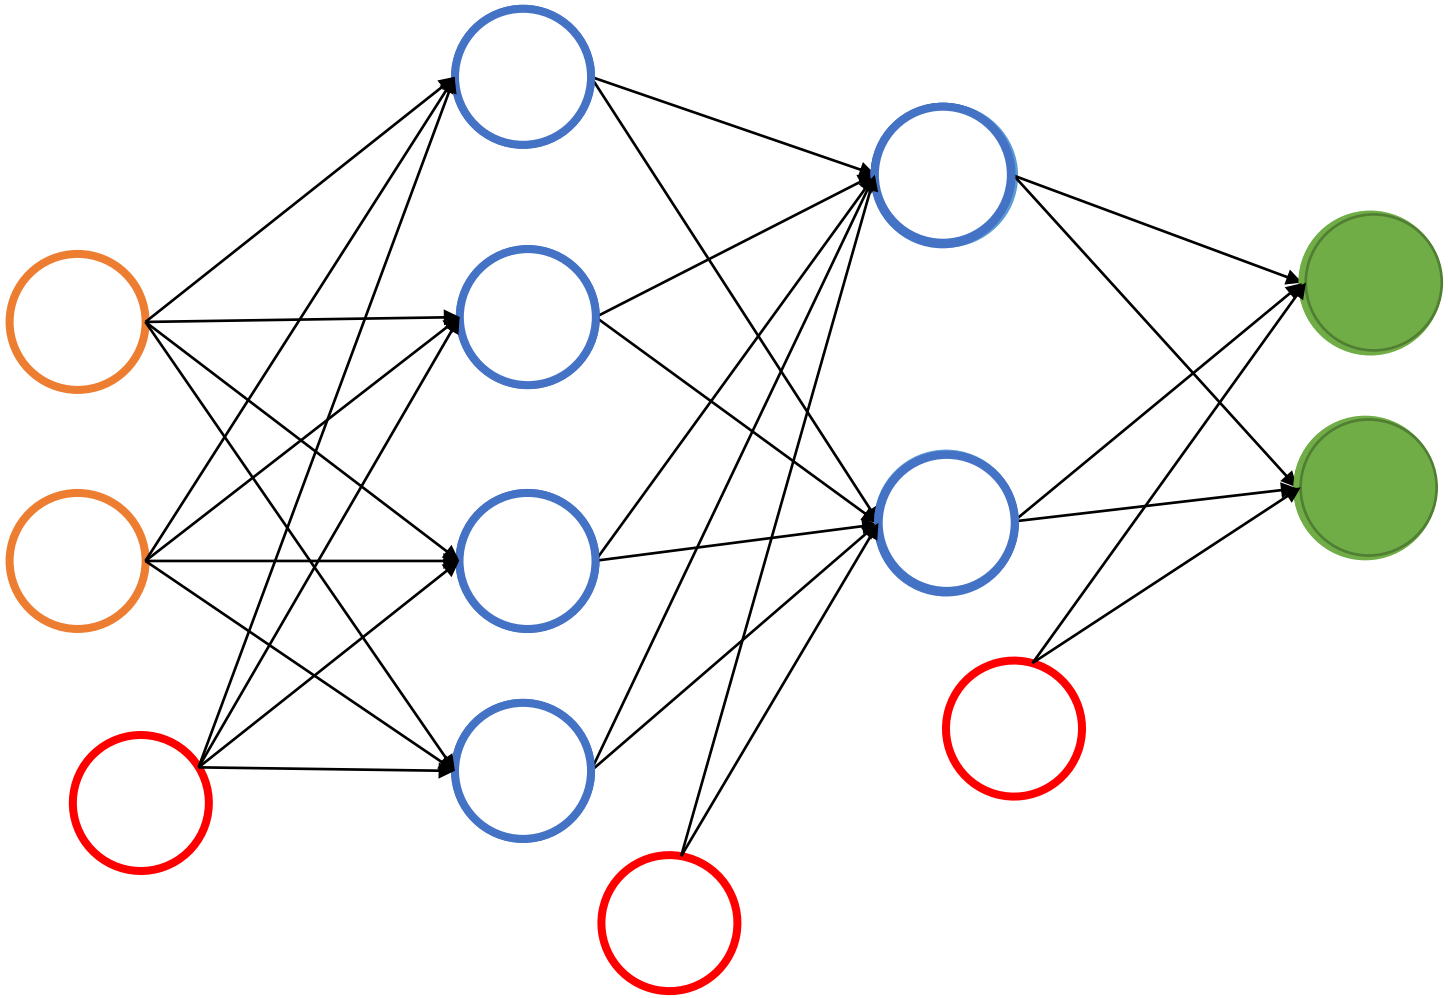

Çıkış nöronları
Output neurons

Ağın sonunda elde edilen çıkış bilgisini barındıran nöronlardır.

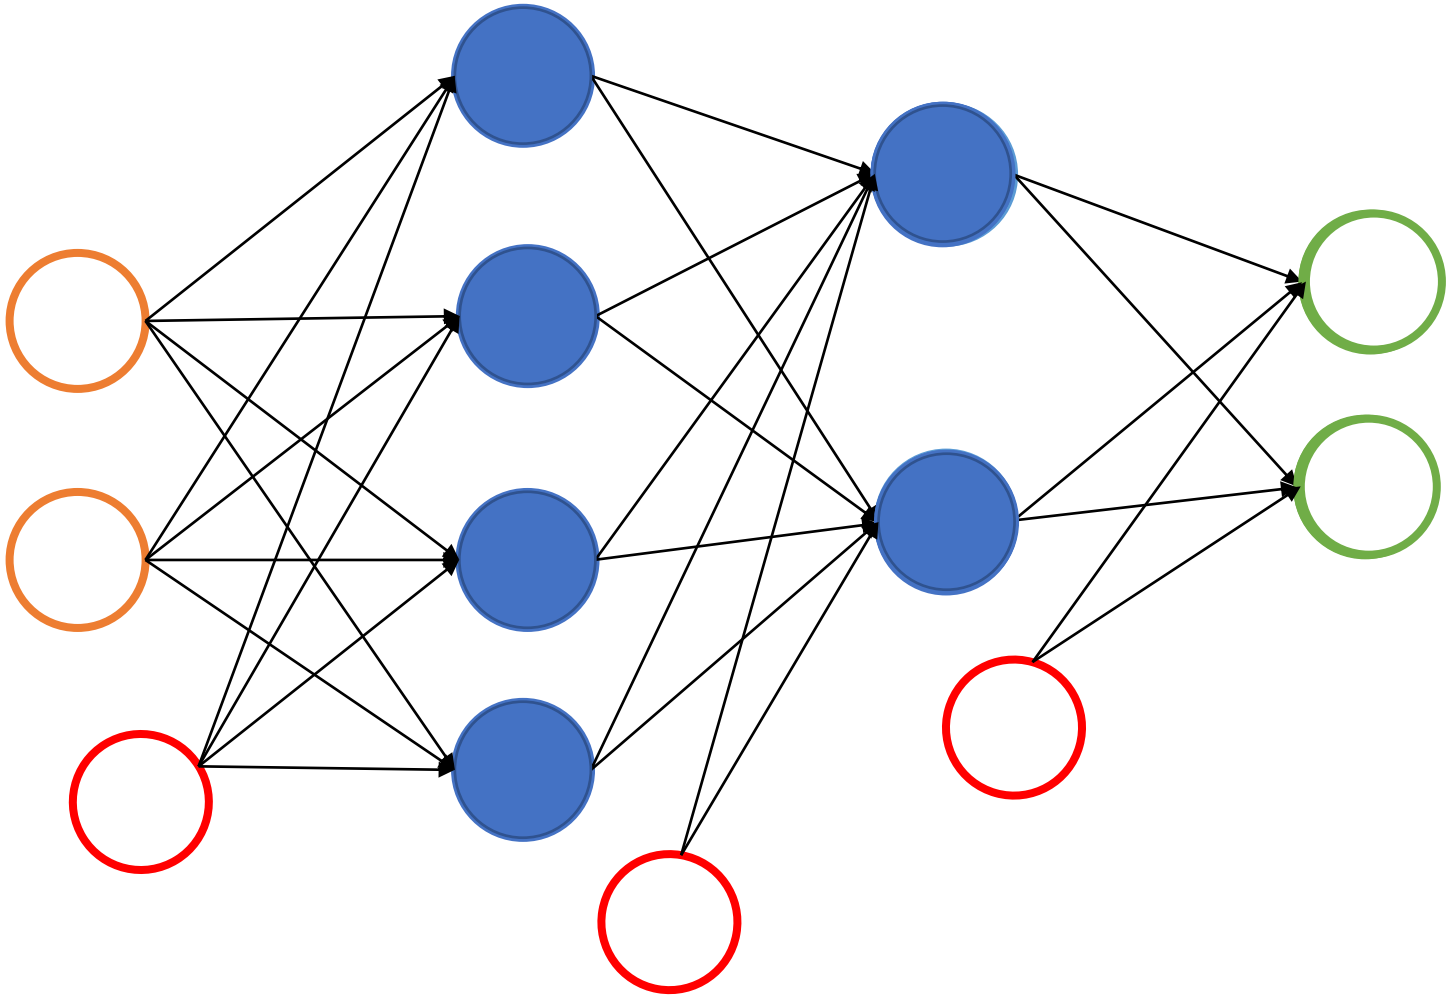

Gizli nöronlar
Hidden neurons

- Giriş, Bias veya kendisinden önceki nöronlarla bağlıdır.
- Çıkışa veya kendinden sonraki nöronlara bağlıdır.
- Giriş ve çıkış arasındaki ilişkiyi belirlemek için kullanılırlar.

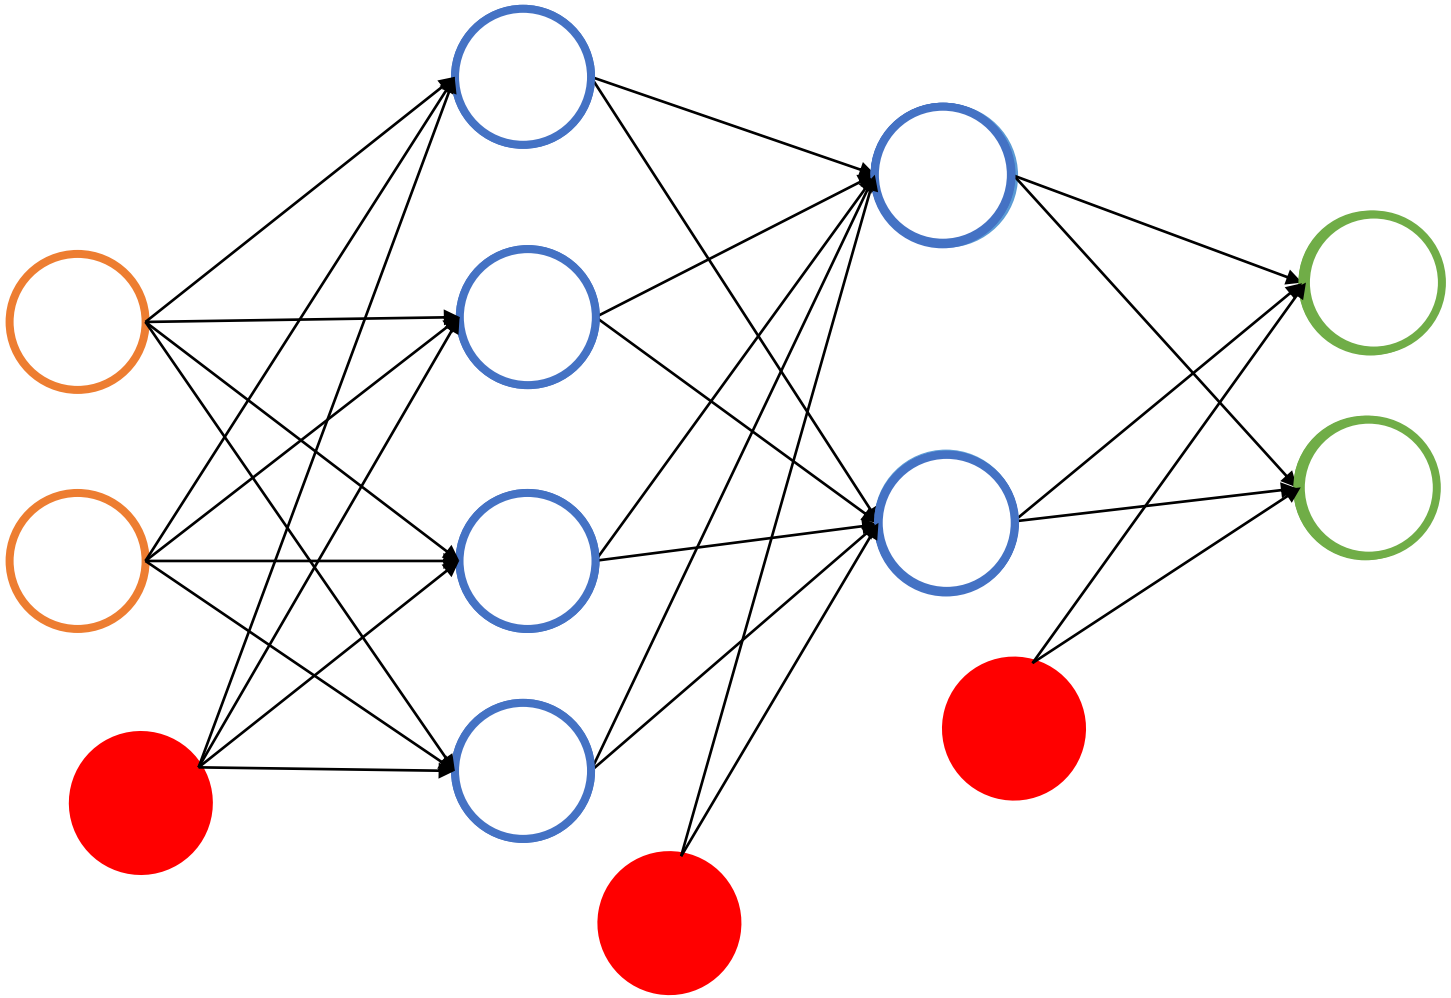

Bias nöronları

Bias neurons

- Nöron çıkıtısını optimize etmek için kullanılan tasarımcı tarafından eklenenebilen nöronlardır.

$$y = x_1 w_1$$

w_1 =-3,4
w_1 =0,5
w_1 =1
w_1 =3,2

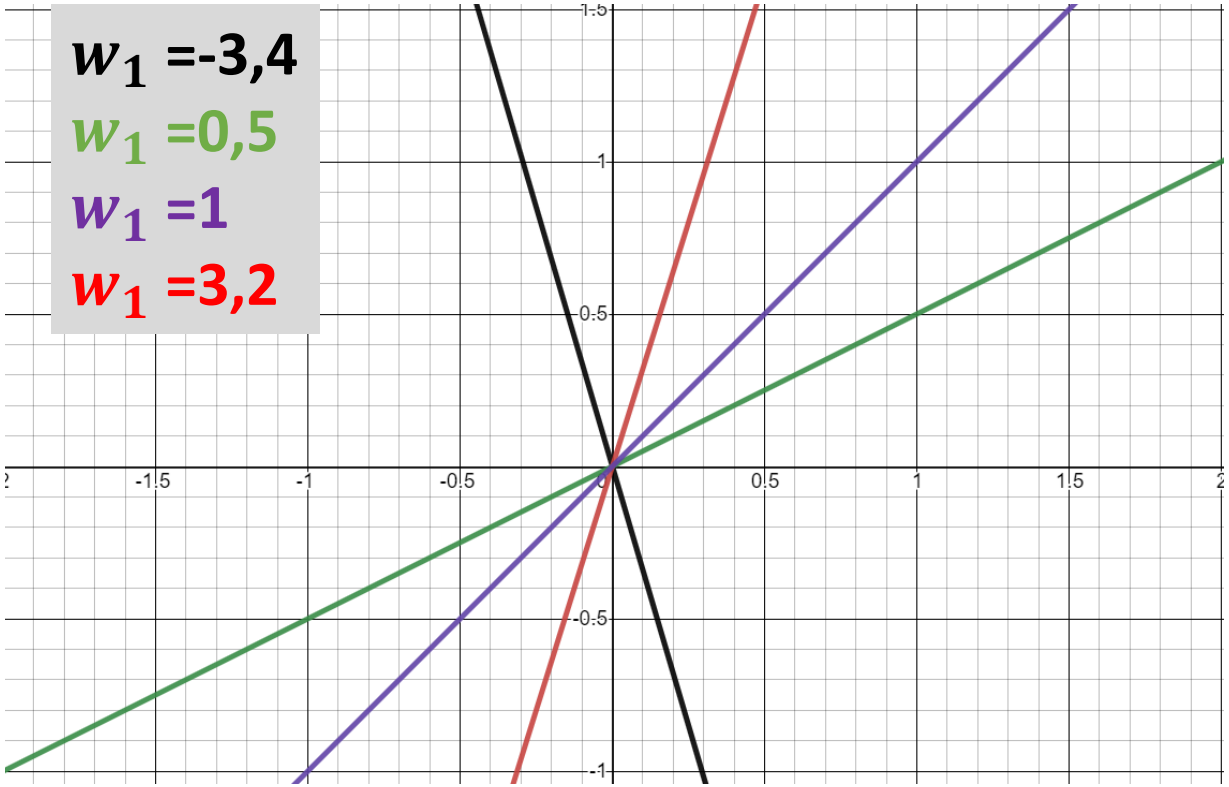

$$y = x_1 w_1 + b$$

w_1 =-3,4
b=0
b =1
b=-1
b=1,5

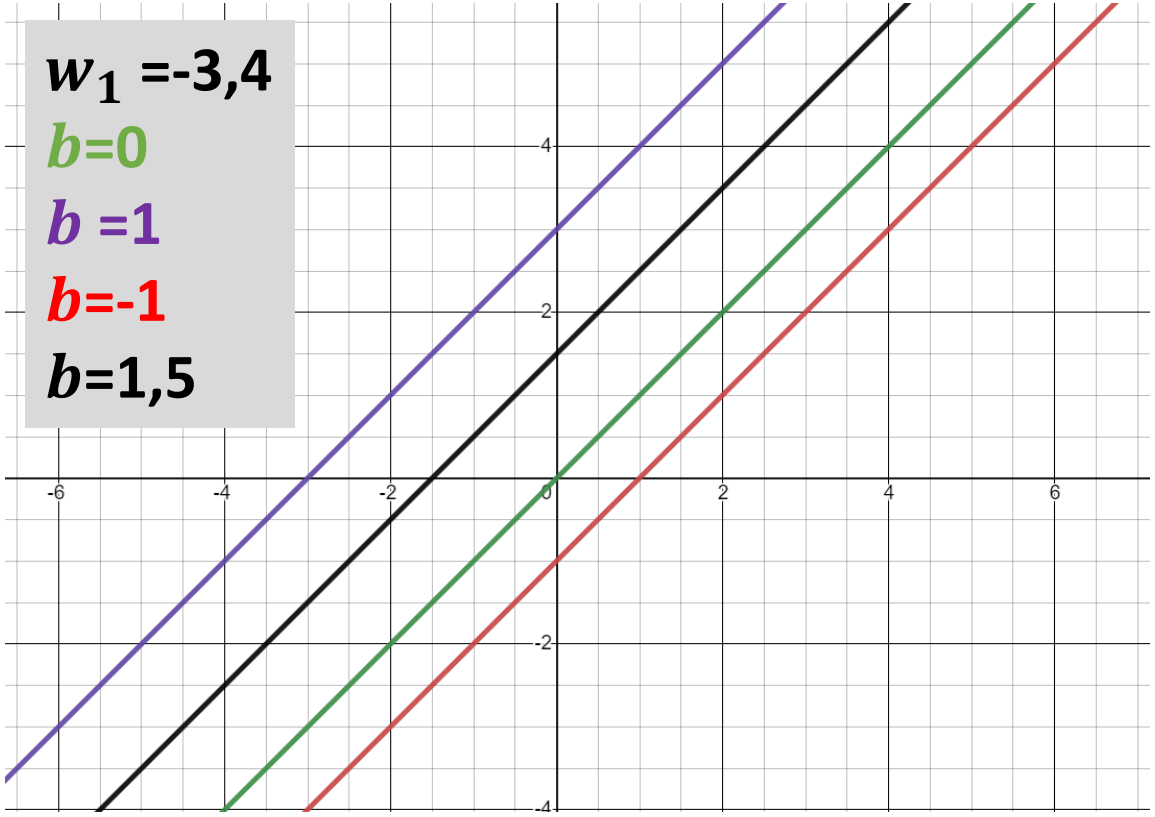

$$y = \frac{1}{1 + e^{-xw}}$$

$$y = \frac{1}{1 + e^{-xw+b}}$$

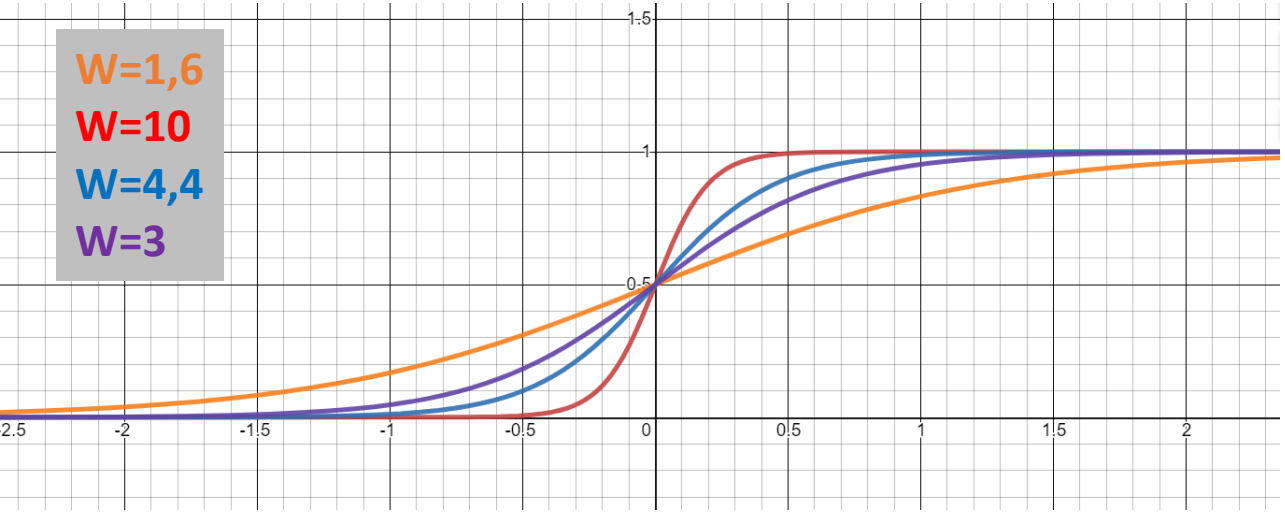

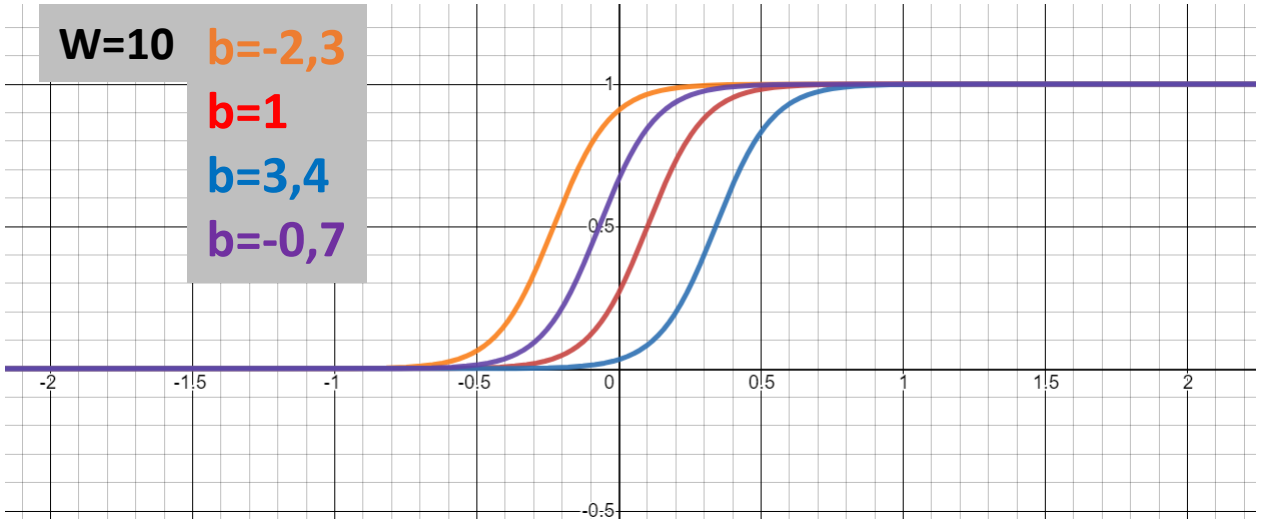

Bias eklenmiş nöron yapısı

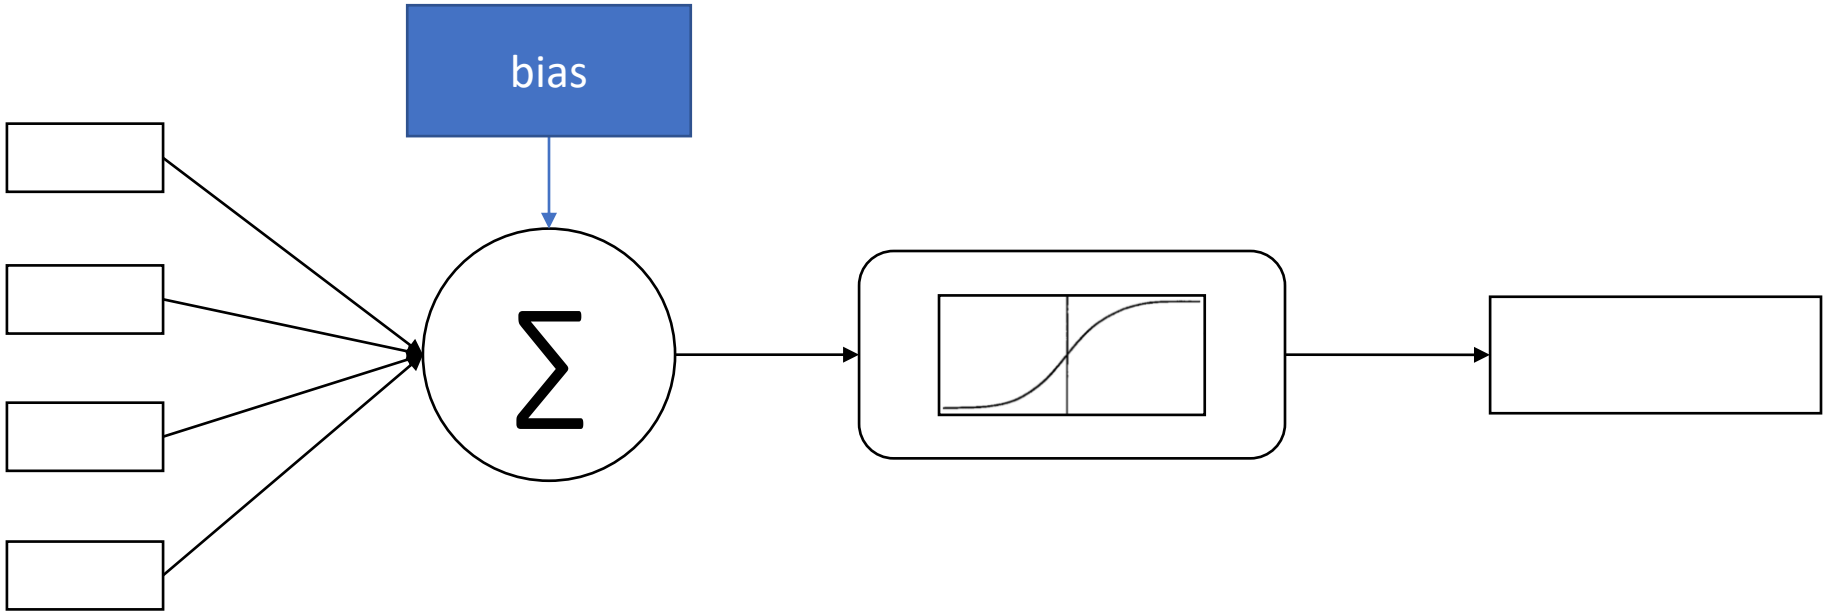

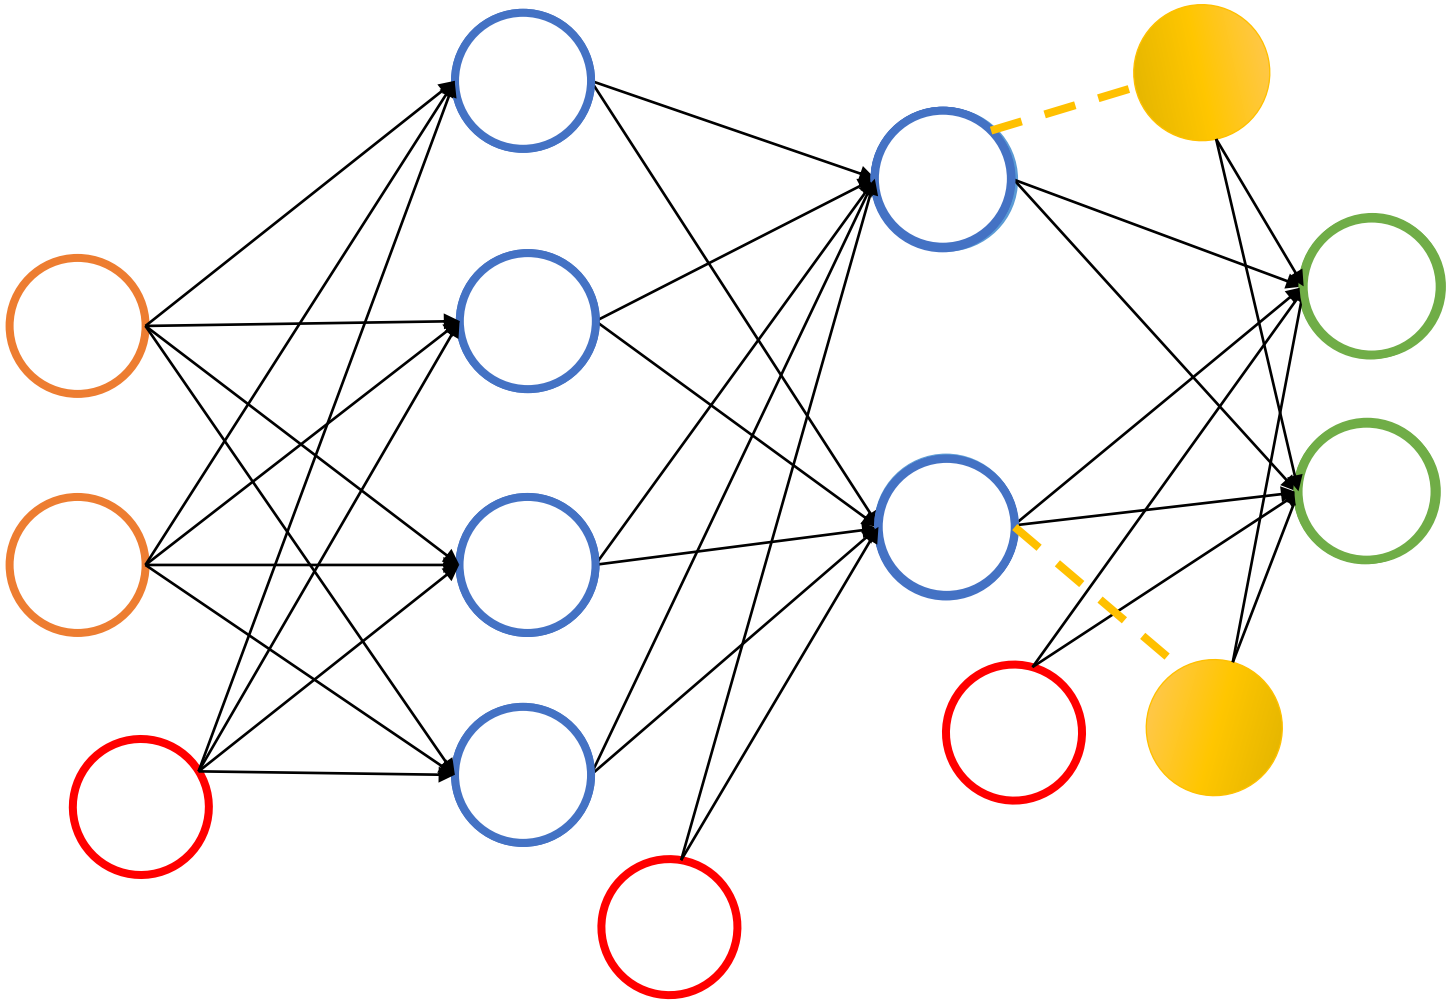

Konteks nöronları

Context neurons

- Sistemin bir önceki durumunu hafızada tutmak için kullanılan kopya nöronlardır.
- Recurrent sinir ağlarında kullanılırlar.
- Video,ses, metin işleme gibi bir önceki zamandaki bilgiye ihtiyaç duyulan uygulamalarda gerekir.


aktivasyon fonksiyonu
activation function

Kesin sınır
hardlimit
Step function

$$\begin{cases} a = 0, & n < 0 \\ a = 1, & n \geq 0 \end{cases}$$

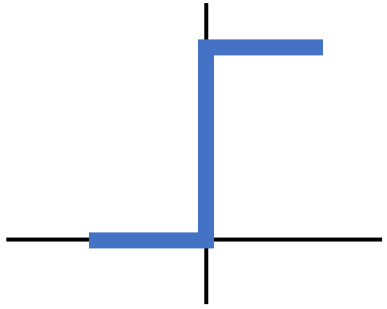

Simetrik kesin sınır
Symetric hardlimit

$$\begin{cases} a = -1, & n < 0 \\ a = 1, & n \geq 0 \end{cases}$$

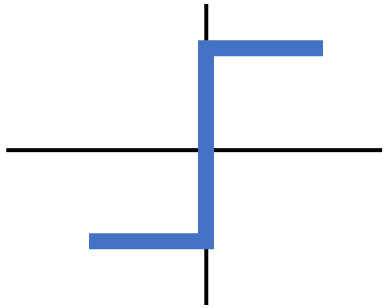

Doğrusal
linear

$$a = n$$

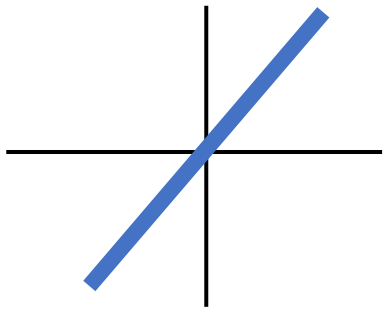

Doygun Doğrusal
saturated linear

$$\begin{cases} a = 0, & n < 0 \\ a = \mathrm{n}, & 1 \geq n \geq 0 \\ a = 1, & n > 1 \end{cases}$$

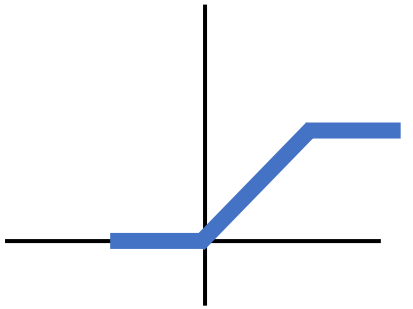

Simetrik Doygun Doğrusal
symetric
saturated linear

$$\begin{cases} a = -1, & n < -1 \\ a = \mathrm{n}, & 1 \geq n \geq -1 \\ a = 1, & n > 1 \end{cases}$$

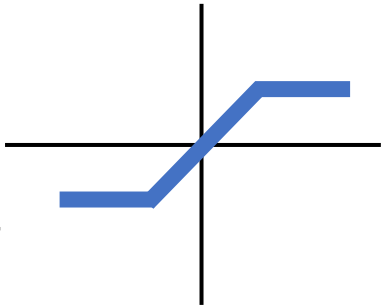

Log Sigmoid

log sigmoid

$$a = \frac{1}{1 + e^{-n}}$$

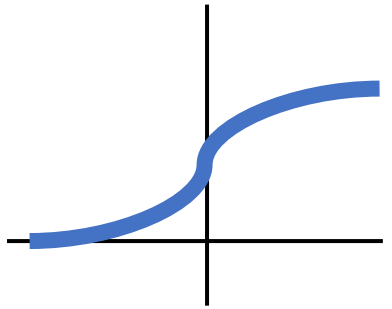

Hiberbolik Tanjant Sigmoid

hyperbolic tangent sigmoid

$$a = \frac{e^{n} - e^{-n}}{e^{n} + e^{-n}}$$

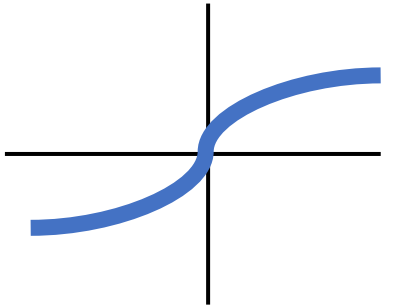

Pozitif doğrusal
positive linear
ReLU

$$\begin{cases} a = 0, & n < 0 \\ a = \mathrm{n}, & n \geq 0 \end{cases}$$

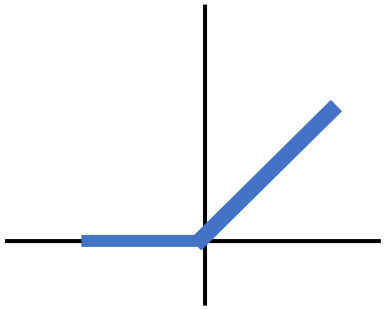

Rekabetçi
competitive

$$\begin{cases} a = 0, & diğer\ tüm\ nöronlar \\ a = 1, & en\ büyük\ \mathrm{n}\ değerli\ nöron \end{cases}$$

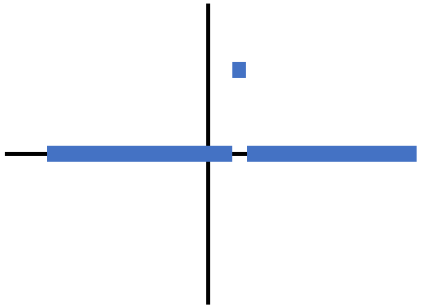

Softmax

softmax

$$\varphi_i = \frac{e^{z_i}}{\sum_{j \in group} e^{z_j}}$$

Sınıflandırma ağlarında kullanılır.
Genelde çıkış katmanında bulunur.
Sınıfın üyeliklerine o grubun % kaç ihtimalle olduğu bilgisini gönderir.

$$\varphi_i = \frac{e^{z_i}}{\sum_{j \in group} e^{z_j}}$$

```
def softmax(giris):
    toplam=0
    for j in giris:
        toplam=toplam+np.exp(j)

    olasilik=[]
    for i in range (len(giris)):
        olasilik.append(np.exp(giris[i])/toplam)
    return olasilik
```

```
def softmax2(X):
    expo = np.exp(X)
    expo_sum = np.sum(np.exp(X))
    return expo / expo_sum
```

Softmax pythonda yazılmış fonksiyon

Test kodu ve ekran çıktısı

```
vector=np.array([0.5,0.32,0.9,0.1])

print(softmax(vector))
k = cv.waitKey(0)
if k == 27:
    cv.destroyAllWindows()
```

```
C:\Users\*****\anaconda3\envs\openCV\pyt
hon.exe
C:/Users/*****/PycharmProjects/goru/ann.p
y
[0.2501616697879043,
0.2089525908107396,
0.3731973573927756,
0.167688382008580 4]
```

Xor Kapısı Xor gate

AND/VE kapısı

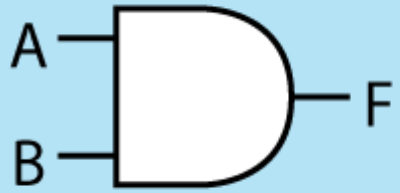

$$F = A * B$$

$$F = AB$$

A	B	F
0	0	0
0	1	0
1	0	0
1	1	1

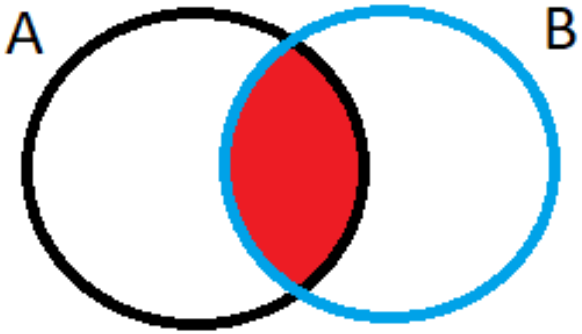

girişler			ağırlıklar				çıkış	
b	x1	x2	wb	w1	w2	toplam	aktivasyon	olması gereken
1	0	0	-1,5	1	1	-1,5	0	0
1	0	1				-0,5	0	0
1	1	0				-0,5	0	0
1	1	1				0,5	1	1

AND/VE kapısı

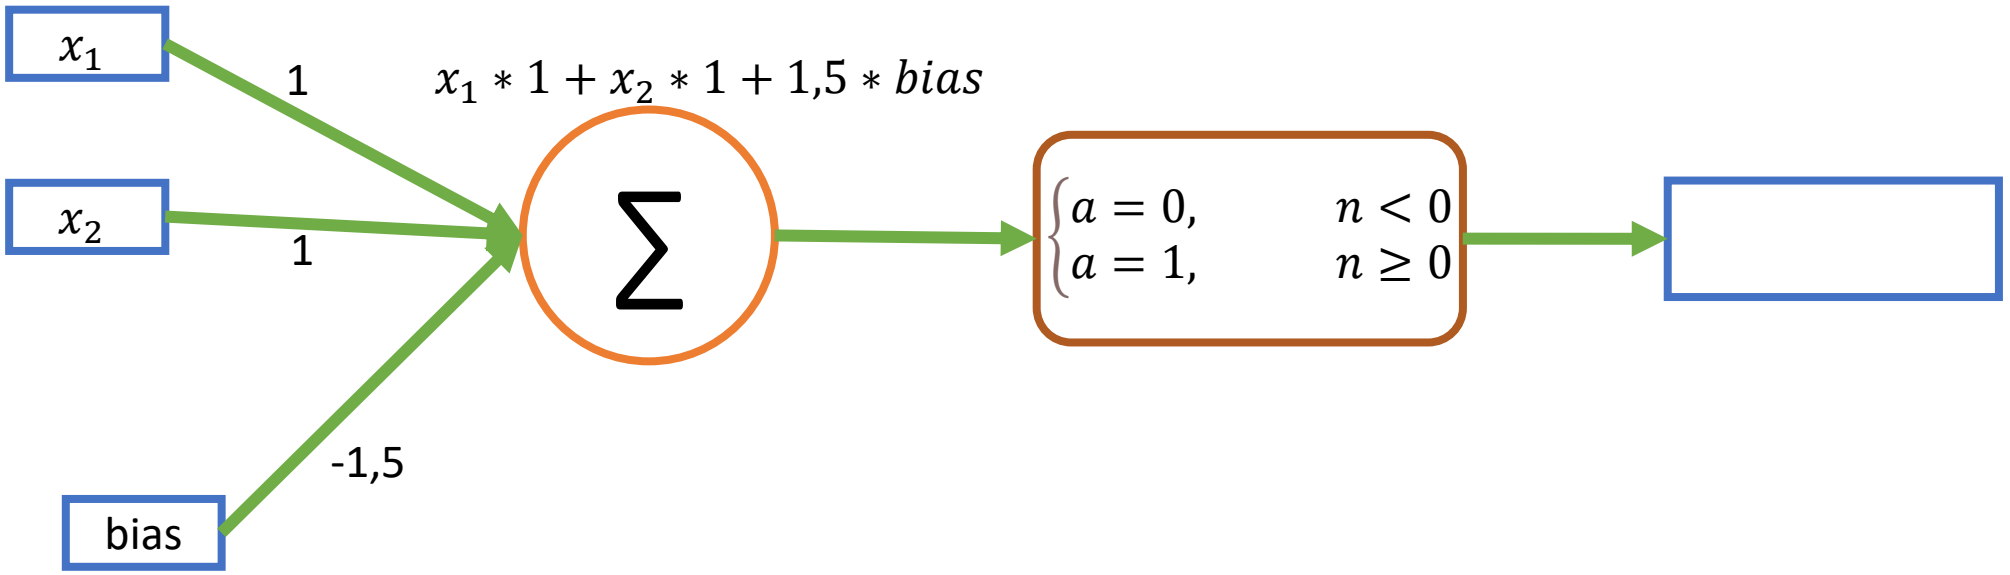

OR/VEYA kapısı

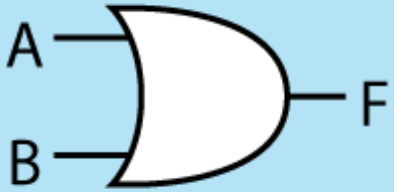

$$F = A + B$$

A	B	F
0	0	0
0	1	1
1	0	1
1	1	1

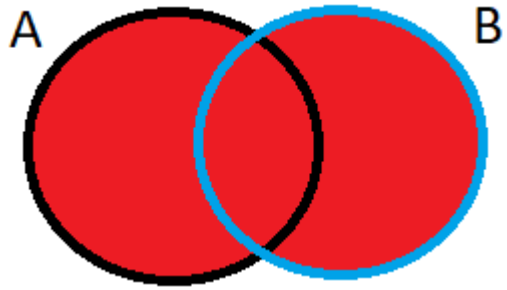

girişler			ağırlıklar				çıkış	
b	x1	x2	wb	w1	w2	toplam	aktivasyon	olması gereken
1	0	0	-0,5	1	1	-0,5	0	0
1	0	1				0,5	1	1
1	1	0				0,5	1	1
1	1	1				1,5	1	1

OR/VEYA kapısı

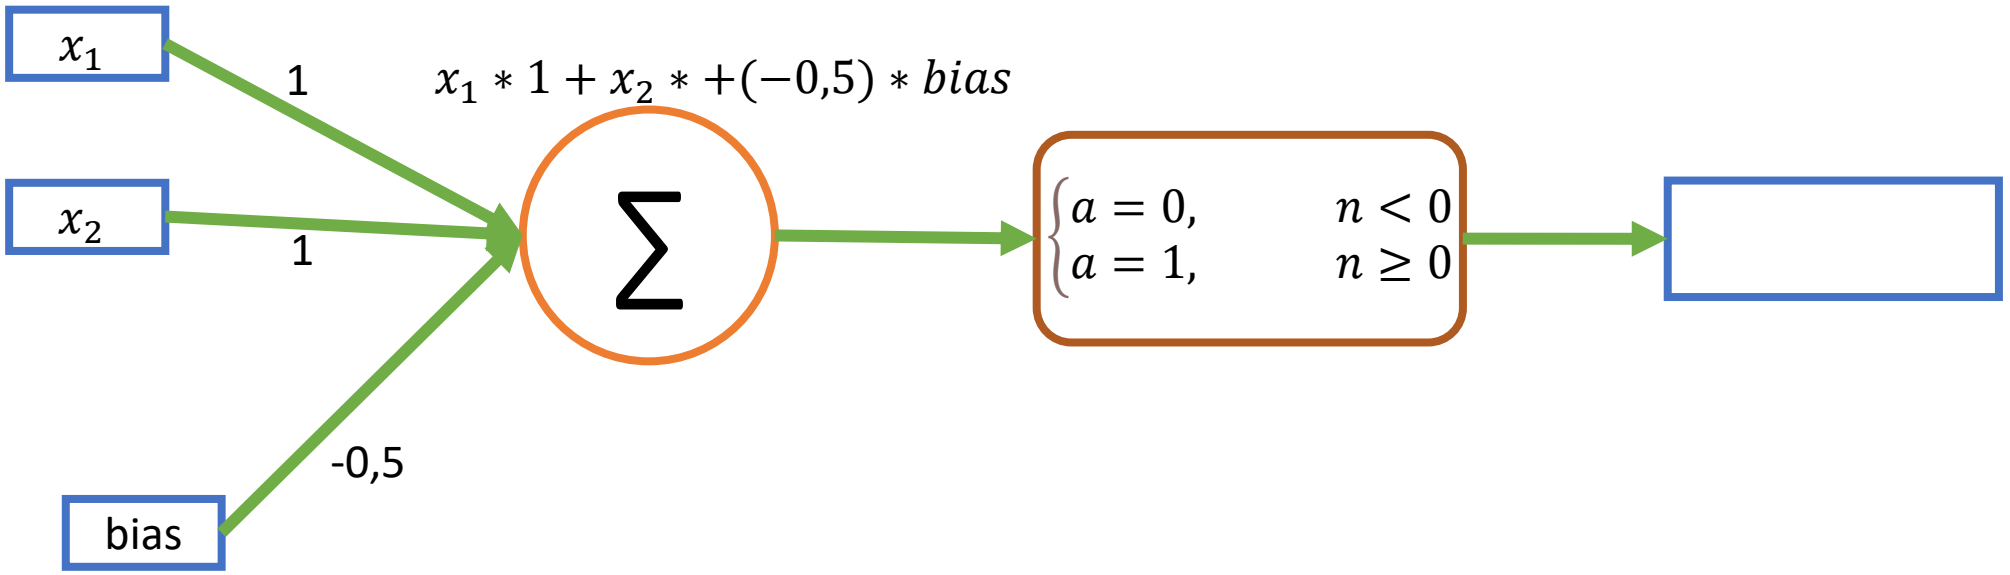

XOR/ ÖZEL VEYA kapısı

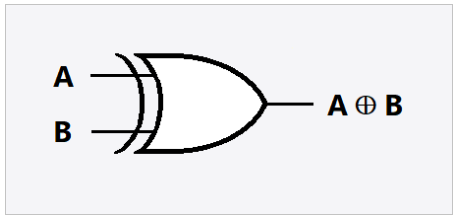

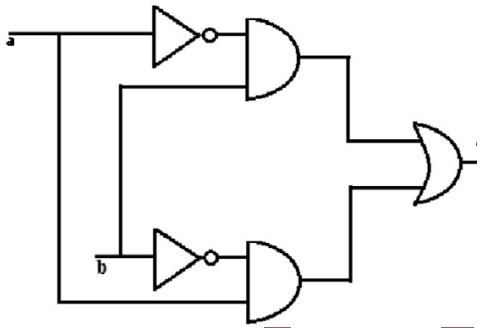

xor		
a	b	f
0	0	0
0	1	1
1	0	1
1	1	0

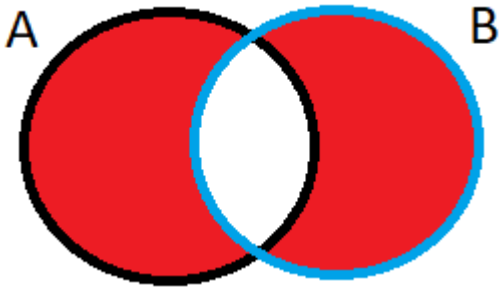

$$f(A,B) = \bar{A}B + \bar{B}A$$

girişler			ağırlıklar				çıkış	
b	x1	x2	wb	w1	w2	toplam	aktivasyon	olması gereken
1	0	0	-0,75	2	1	-0,75	0	0
1	0	1				0,25	1	1
1	1	0				1,25	1	1
1	1	1				2,25	1	0

AND/VE kapısı

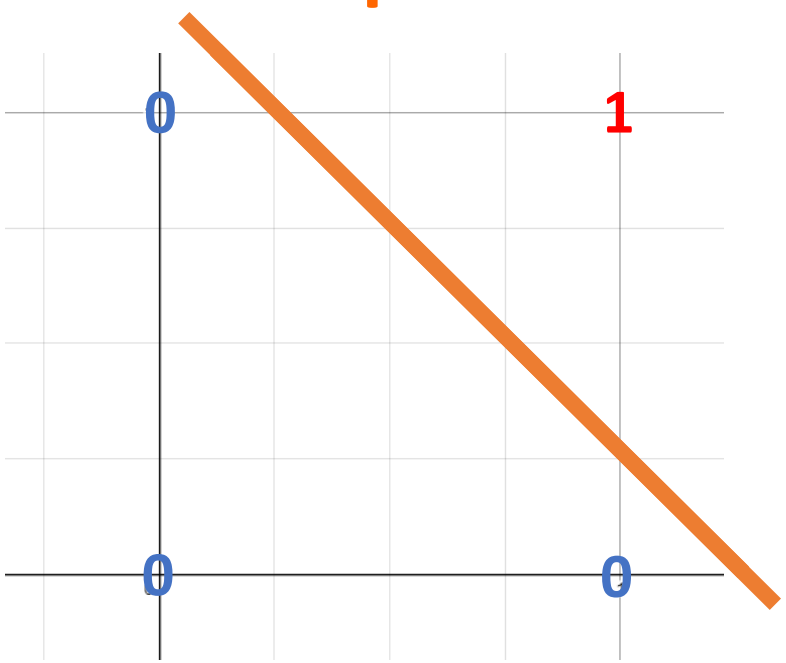

OR/VEYA kapısı

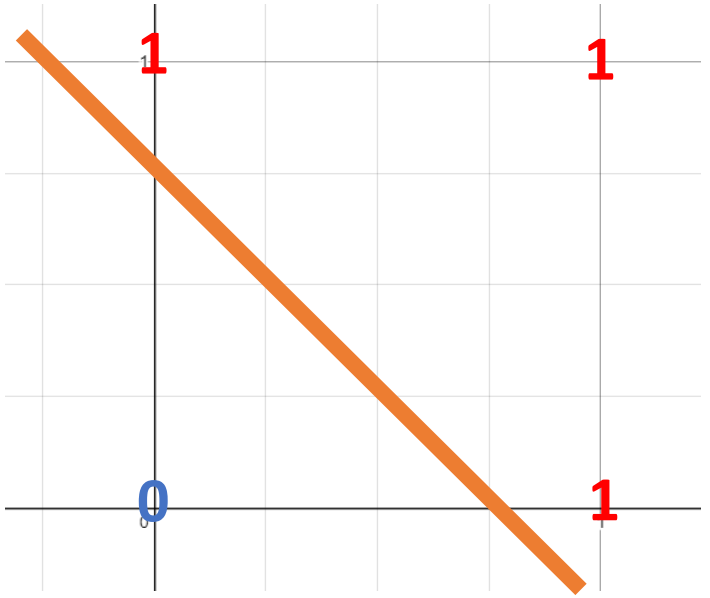

XOR/ ÖZEL VEYA kapısı

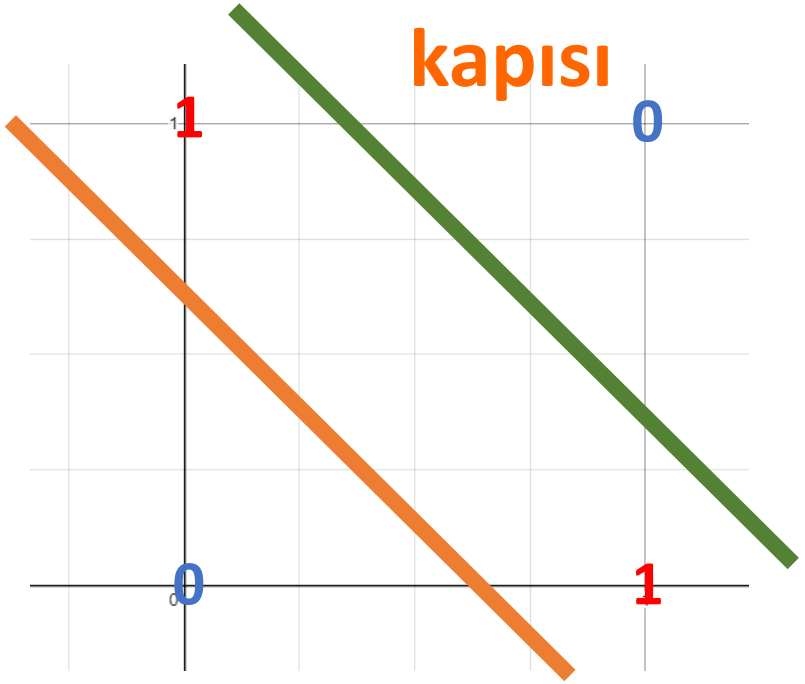

XOR/ ÖZEL VEYA kapısı

a	b	ab	a+b	aXORb
0	0	0	0	0
0	1	0	1	1
1	0	0	1	1
1	1	1	1	0

XOR/ ÖZEL VEYA kapısı

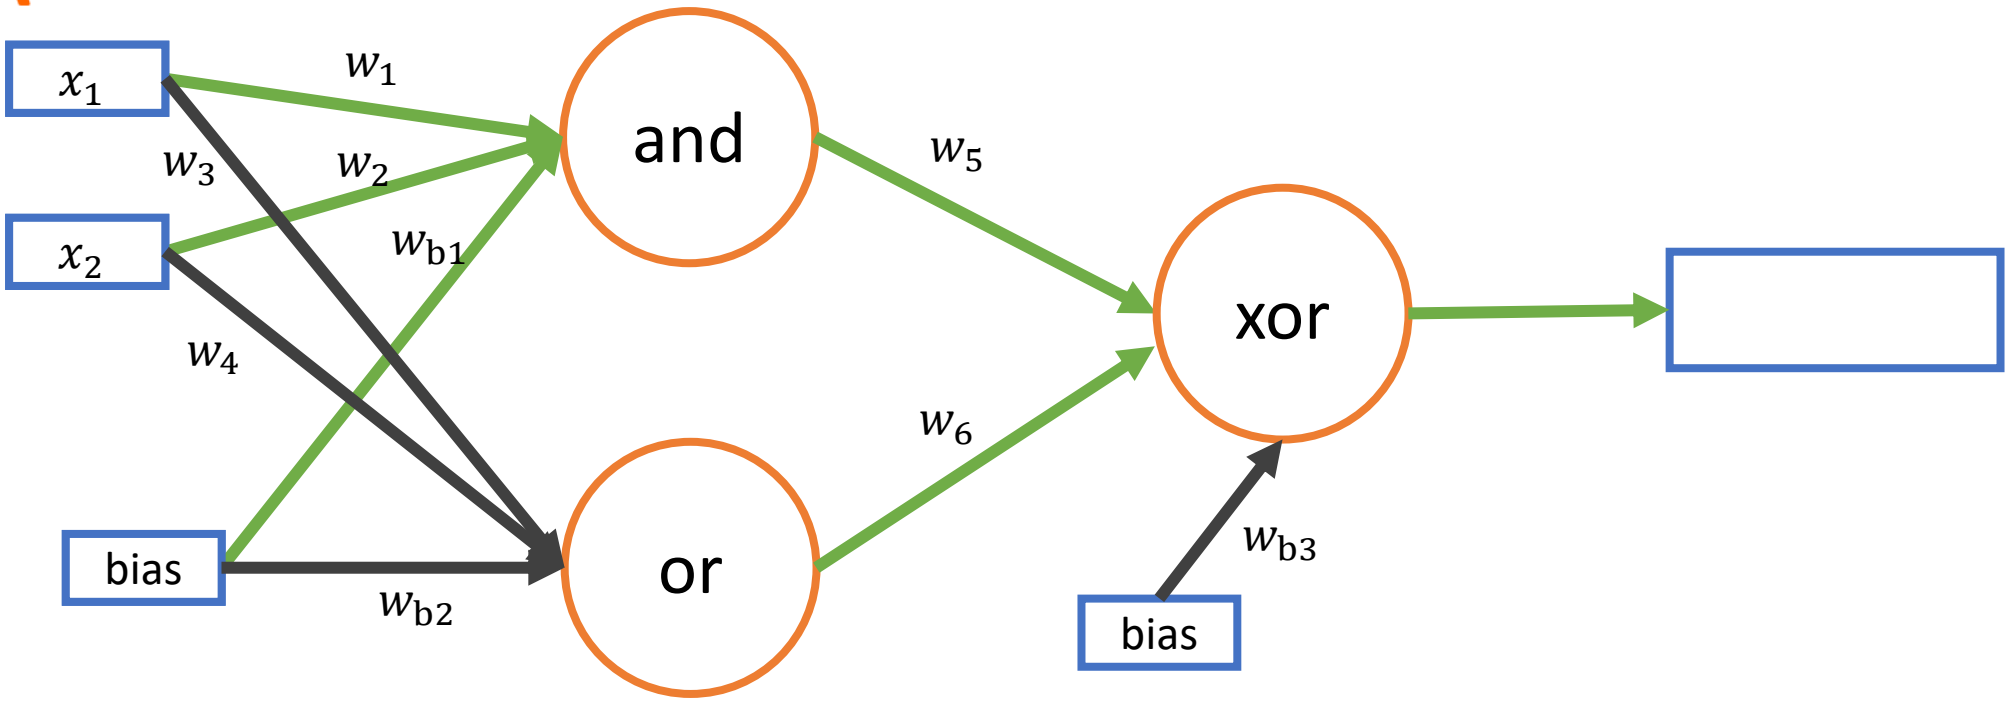

XOR/ÖZEL VEYA kapısı

AND VE KAPISI

girişler			ağırlıklar				çıkış	
b	x1	x2	wb1	w1	w2	toplam	aktivasyon	olması
1	0	0	-1,5	1	1	-1,5	0	0
1	0	1				-0,5	0	0
1	1	0				-0,5	0	0
1	1	1				0,5	1	1

OR

ağırlıklar				çıkış	
wb2	w3	w4	toplam	aktivasyon	olması
-0,5	1	1	-0,5	0	0
			0,5	1	1
			0,5	1	1
			1,5	1	1

XOR

b	and çıkış	or çıkış	wb3	x5	x6	toplam	aktivasyon	olması gereken
1	0	0	-2	-1	2	-2	0	0
1	0	1				0	1	1
1	0	1				0	1	1
1	1	1				-1	0	0

XOR/ ÖZEL VEYA kapısı

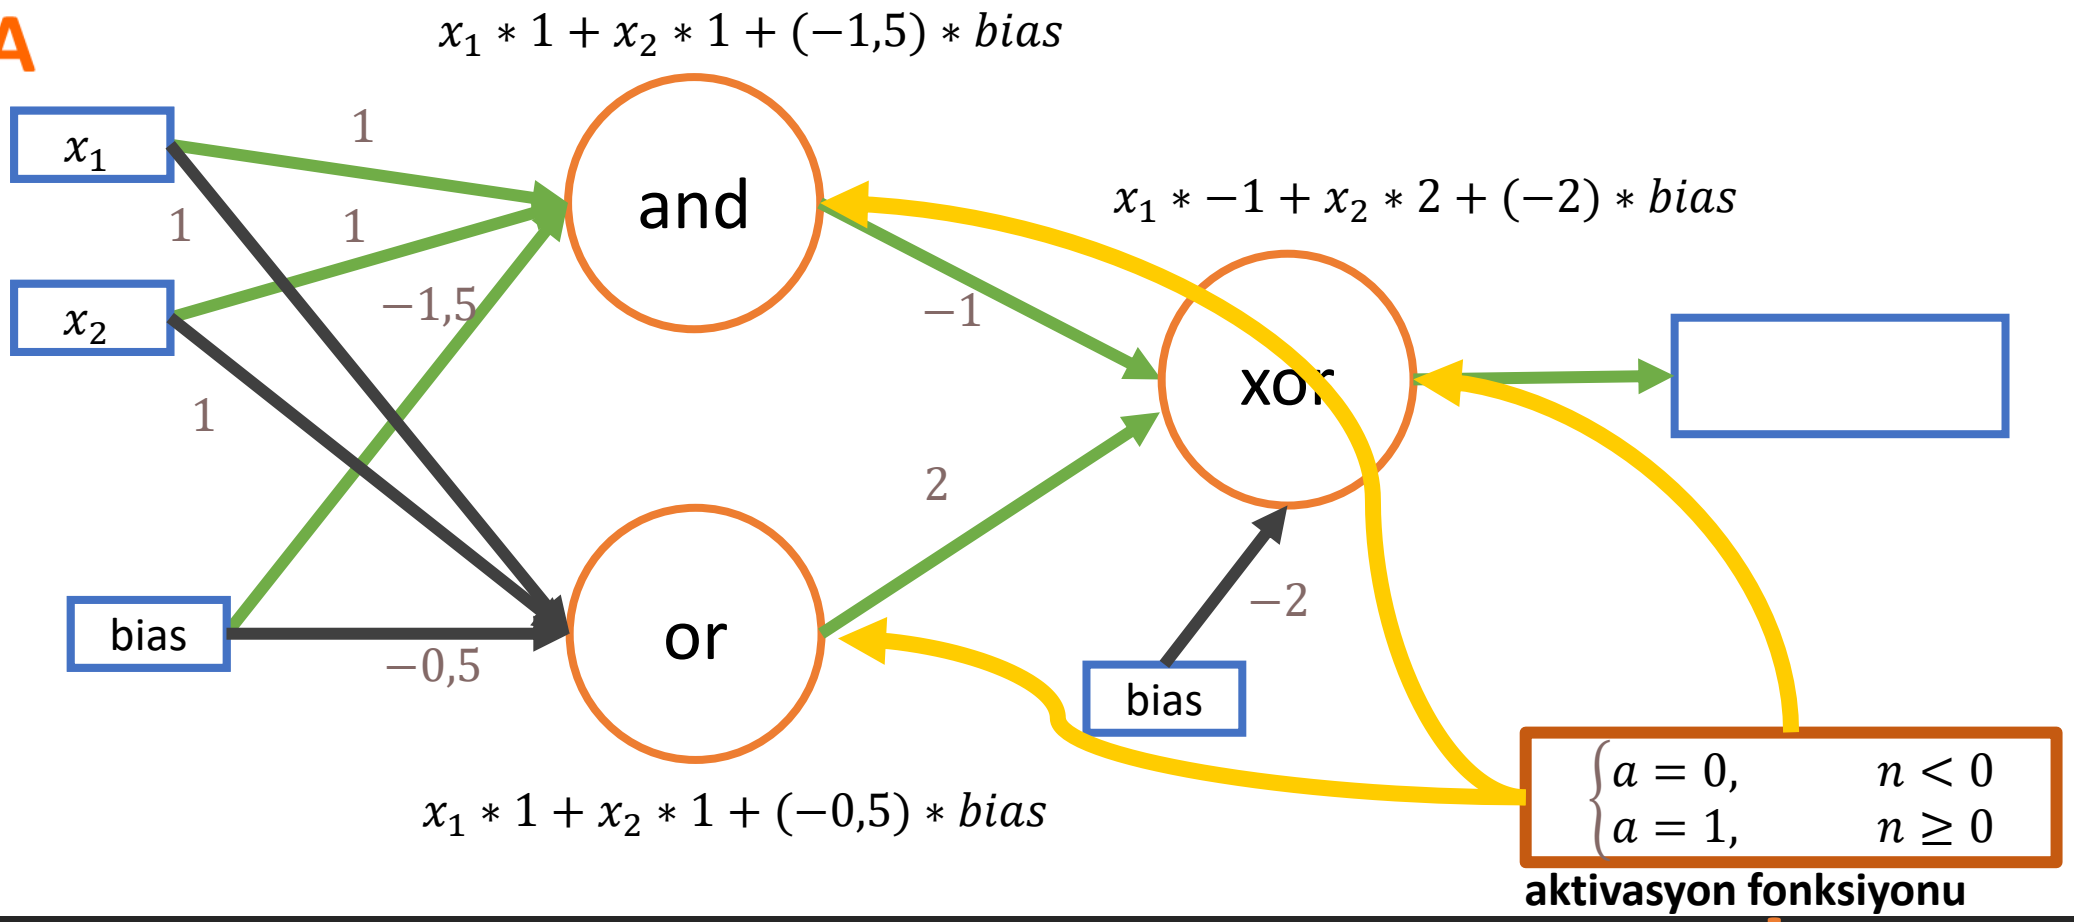

Ağırlıkların elle hesaplanması zor bir iş...
Peki bilgisayarlar bu ağırlıkları nasıl hesaplıyor?


Ysa nasıl öğrenir?
How ann learns?


hata error

Hata = elde edilen **ölçülen değer** (actual value) – gerçek **olması gereken değer** (ideal value)
Error

Yerel Hata
local error

- Her tek bir nöronun mevcut durumu ve olması gereken değeri arasındaki farktır.
- Hata fonksiyonu ile hesaplanır.

Genel Hata
global error

- Yerel hataların bir araya gelmesi ile oluşan ağın toplam hatasıdır.
- Sinir Ağının eğitim setine ne kadar iyi cevap verdiğinin göstergesidir.

Hata kareler toplamı
Ortalama Kareler Hatası
Ortalama Karekök Hatası

Yerel Hata
local error

Doğrusal Hata Fonksiyonu Linear Error Function

$$E = (x - m)$$

x: olması beklenen değer
m: nöronun mevcut değeri

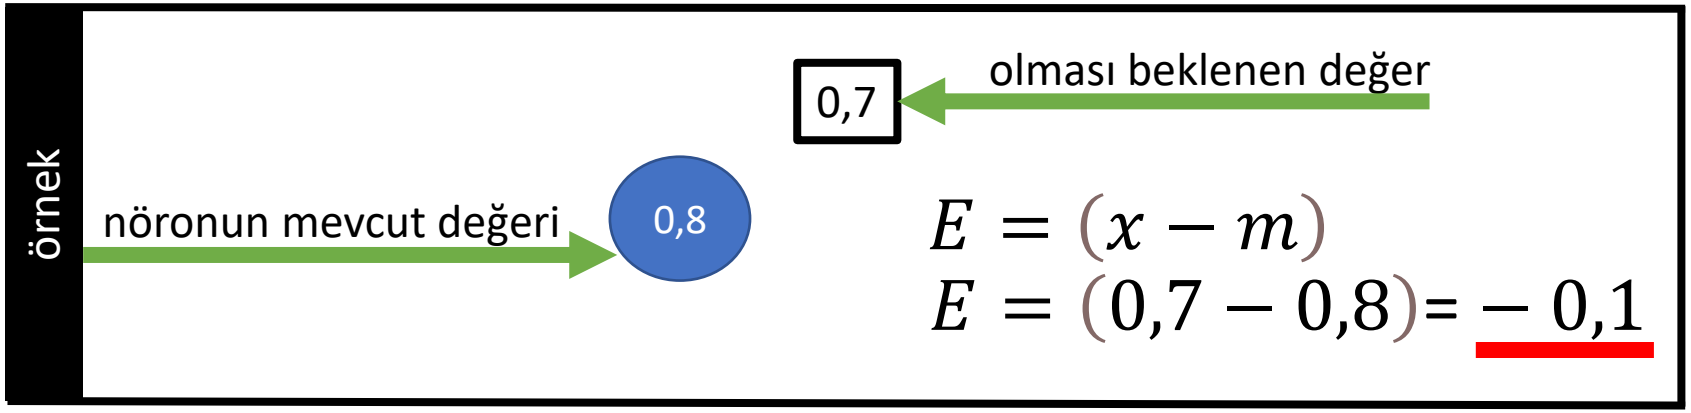

$|E|$

Hatanın mutlak değerinin büyüklüğü arzu edilen değerden ne kadar uzaklaşıldığını gösterir.
Hatanın işareti ise ağırlık düzeltmelerinde artış veya azalış yapılması gerektiği hakkında bilgi verir.

$\pm E$

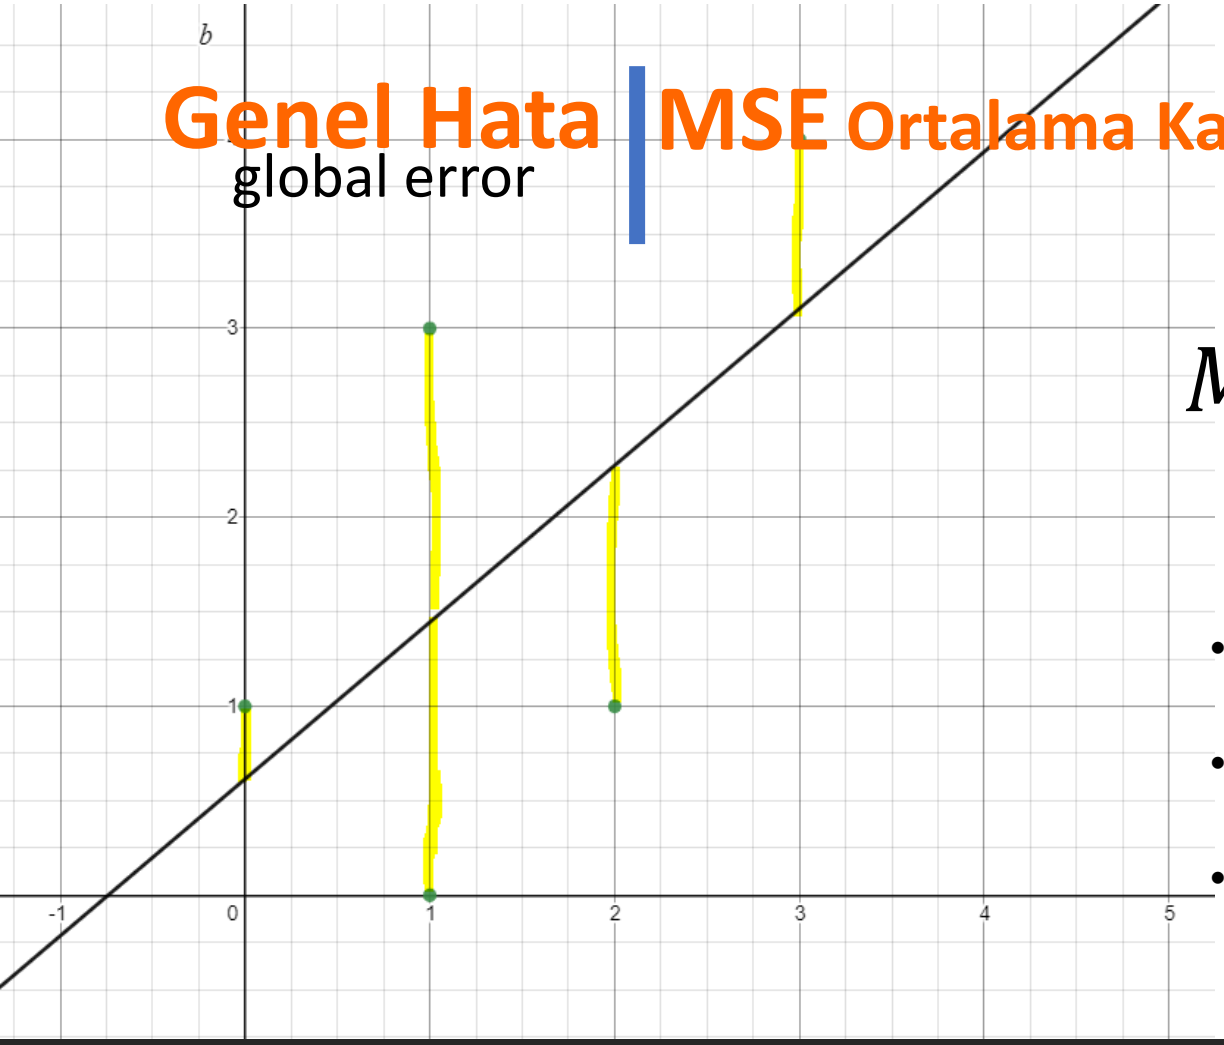

Genel Hata | MSE Ortalama Kare Hatası Mean Square Error

global error

$$MSE = \frac{1}{n}\sum_{i=1}^{n} E^2$$

E: yerel hata

n: yerel hata sayısı

- MSE regresyon çizgisinin veri setindeki noktalara ne kadar uzakta olduğunu söyler.
- Regresyon çizgisi üzerindeki noktaların veri setindeki noktalara uzaklığı hesaplanarak hata bulunur.
- Kare kullanılması hem negatif işareti kaldırır hem de değerler arasındaki farkı arttıran bir ağırlık görevi görür.

Genel Hata
global error

SSE Hata Kareler Toplamı
Sum of Squares Error
Residual sum of squares

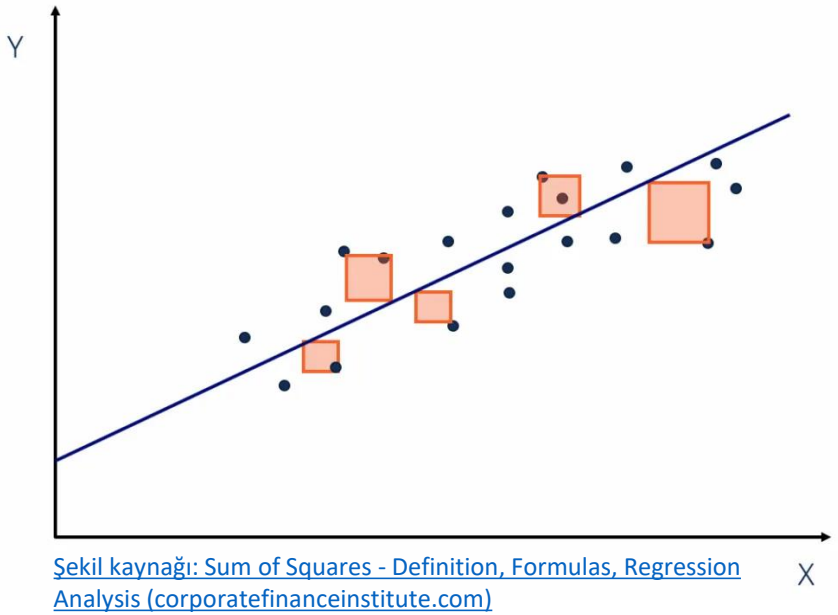

Şekil kaynağı: Sum of Squares - Definition, Formulas, Regression Analysis (corporatefinanceinstitute.com)

$$SSE = \frac{1}{2}\sum_{i=1}^{n} E^2$$

E: yerel hata

- Hataların kareleri toplamı hata sayısına değil 2'ye bölünür.
- Genel olarak, daha düşük bir Hata kareler toplamı, regresyon modelinin verileri daha iyi açıklayabildiğini gösterirken, daha yüksek bir hata kareler toplamı, modelin verileri zayıf bir şekilde açıkladığını gösterir.
- Bazı eğitim algoritmalarında kullanılır.
  Levenburg-Marguardt Algoritması(LMA)

Genel Hata
global error

RMSE Kök Ortalama Kare Hata

Root Mean Square Error

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n} E^2}$$

E: yerel hata

- Elektronik sistemlerde daha çok kullanılır.

- Genel olarak, daha düşük bir Hata kareler toplamı, regresyon modelinin verileri daha iyi açıklayabildiğini gösterirken, daha yüksek bir hata kareler toplamı, modelin verileri zayıf bir şekilde açıkladığını gösterir.
- Bazı eğitim algoritmalarında kullanılır.
  Levenburg-Marguardt Algoritması(LMA)


eğimslope

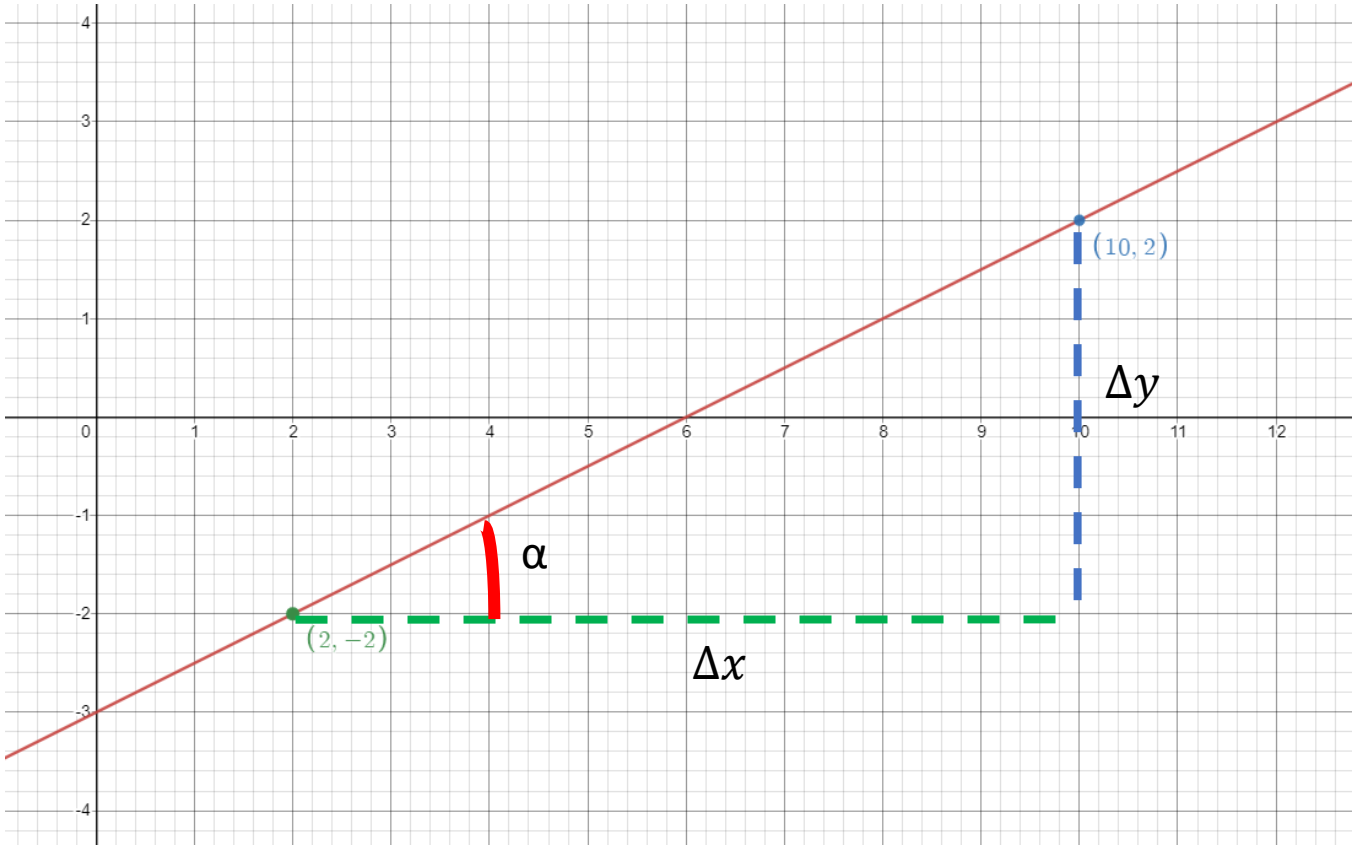

$$\text{eğim} = \frac{y'\text{teki değişim}}{x'\text{deki değişim}}$$

$$m = \frac{\Delta y}{\Delta x} = \frac{y_2 - y_1}{x_2 - x_1}$$

$$m = \tan(\alpha)$$

$$y = mx + b$$

eğim

Y ekseni kesim noktası

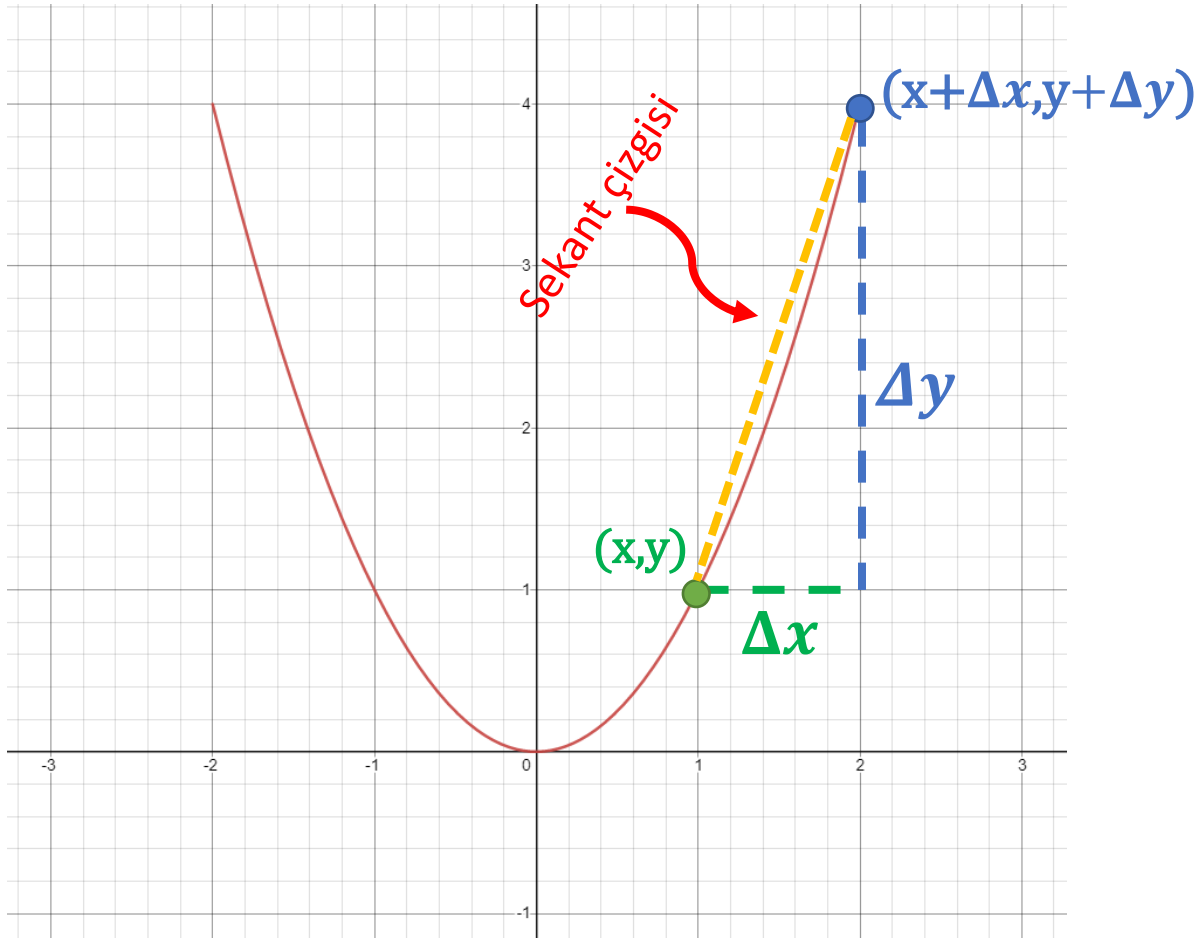

$$\text{eğim} = \frac{y'\text{teki değişim}}{x'\text{deki değişim}}$$

$$m = \frac{\Delta y}{\Delta x} = \frac{y_2 - y_1}{x_2 - x_1}$$

$$m = \frac{f(x + \Delta x) - f(x)}{(x + \Delta x) - x}$$

$$f'_{(x)} = \lim_{h \to 0} \frac{f(x + h) - f(x)}{(x + h) - x}$$

$$f'_{(x)} = \lim_{h \to 0} \frac{f(x + h) - f(x)}{h}$$

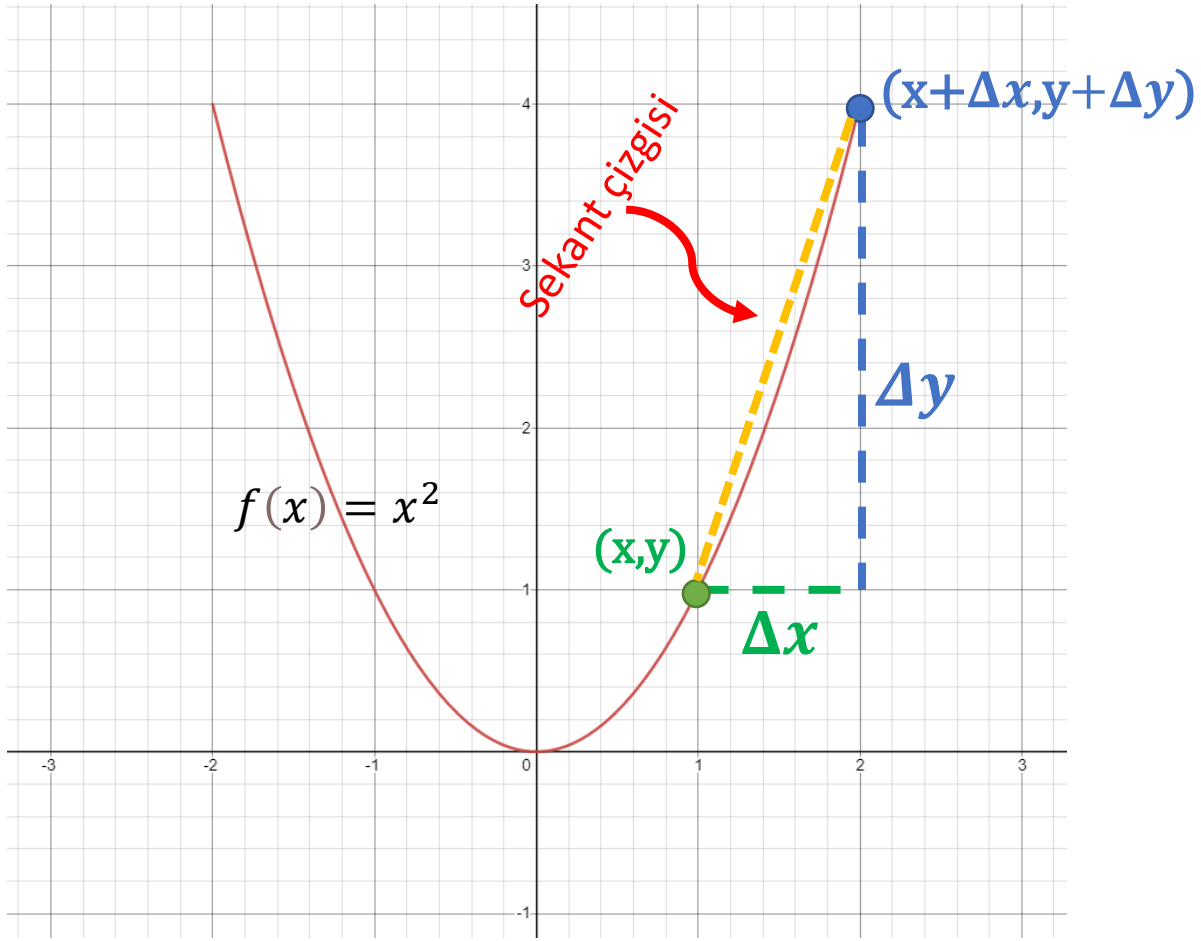

$$f'_{(x)} = \lim_{h \to 0} \frac{f(x+h) - f(x)}{h}$$

$$f'_{(x)} = \lim_{h \to 0} \frac{x^2 + 2xh + h^2 - x^2}{h}$$

$$f'_{(x)} = \lim_{h \to 0} \frac{2xh + h^2}{h}$$

$$f'_{(x)} = \lim_{h \to 0} 2x + h$$

$$f'_{(x)} = 2x$$

$$f'_{(x)} = \mathrm{n}x^{n-1}$$

$\frac{\partial r}{\partial y}$ y'nin r deki değişimi

$$r = f(x, y) = x^2 + xy + y^2$$

$$\frac{\partial r}{\partial x} = 2x + y \qquad \frac{\partial r}{\partial y} = 2y + x$$

Sinir ağındaki hatanın ağırlıklara göre kısmi türevi alınır.

$$(f \circ g)'(t) = f'\big(g(t)\big)\, g'(t)$$

Tüm ağda türevlerin hesaplanmasında kısmi türevler önem arz etmektedir.

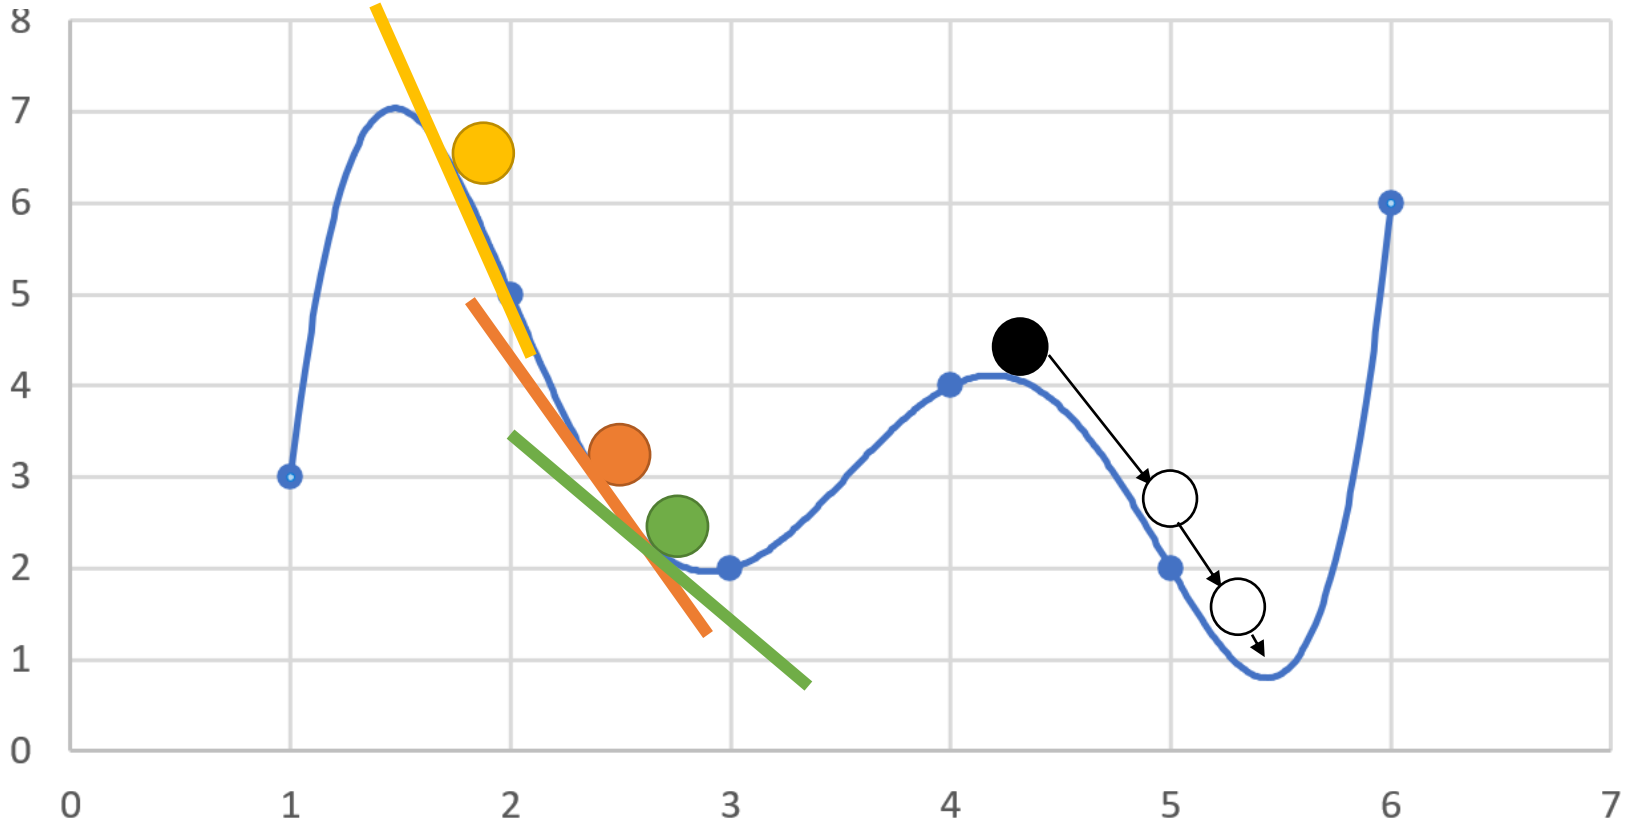

Dereceli alçalma
bir fonksiyonun yerel minimumunu bulmak için kullanılan yinelemeli bir optimizasyon algoritmasıdır.

1847 Baron Augustin-Louis Cauchy
Dereceli alçalma genellikle Cauchy'ye atfedilir.
en dik iniş

1944 Haskell Curry
Doğrusal olmayan optimizasyon problemleri için yakınsama özelliklerini incelenmiştir.

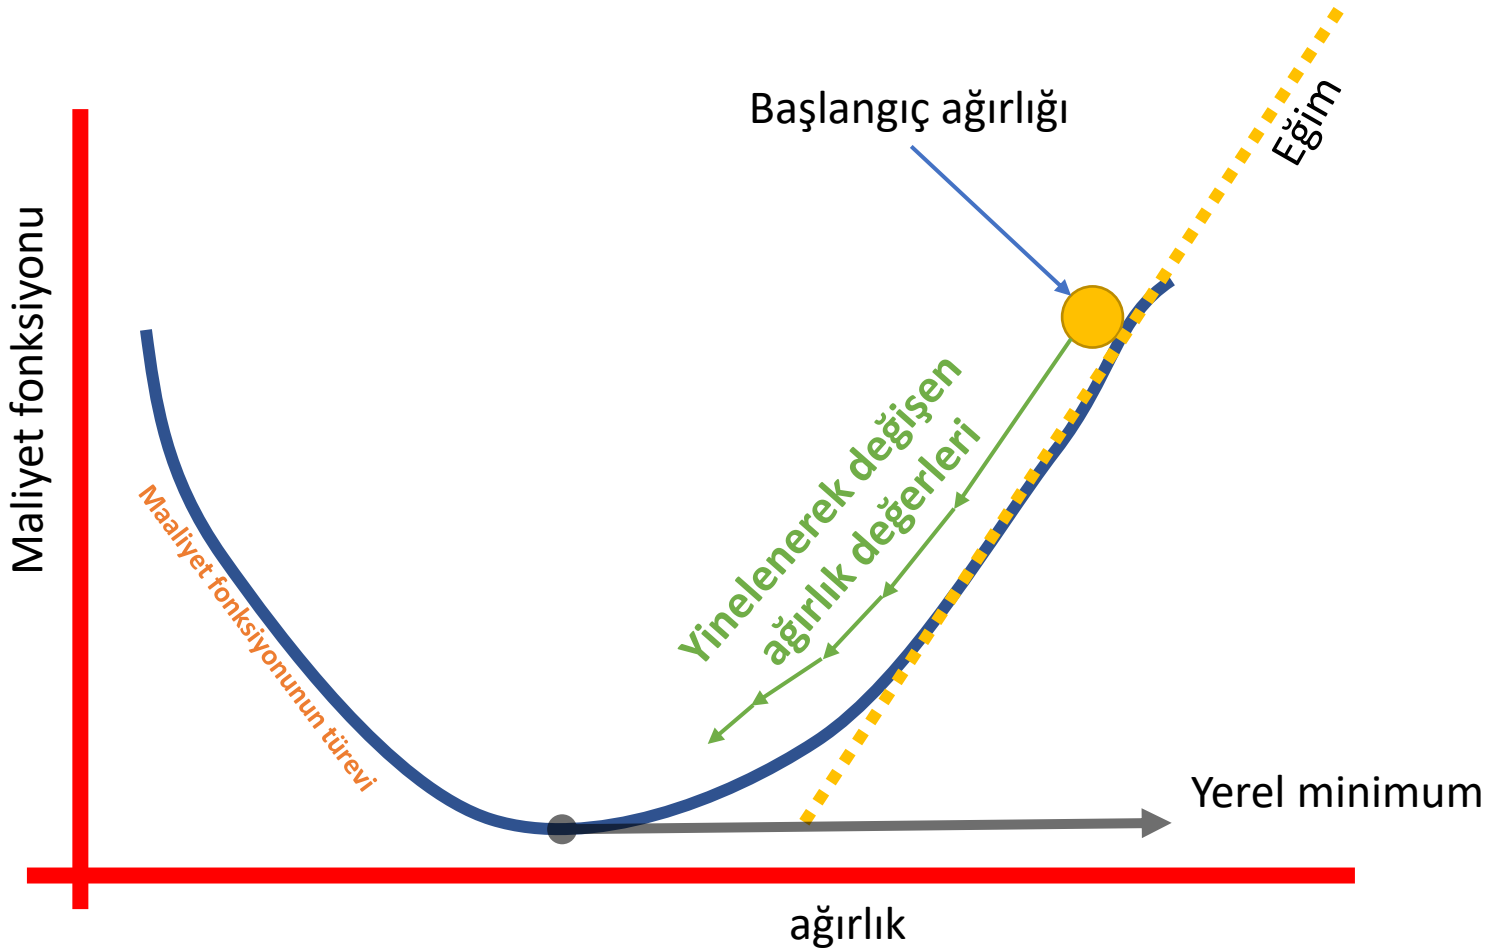
Başlangıç ağırlığı
Eğim
Maliyet fonksiyonu
Maaliyet fonksiyonunun türevi
Yinelenerek değişen
ağırlık değerleri
Yerel minimum
ağırlık

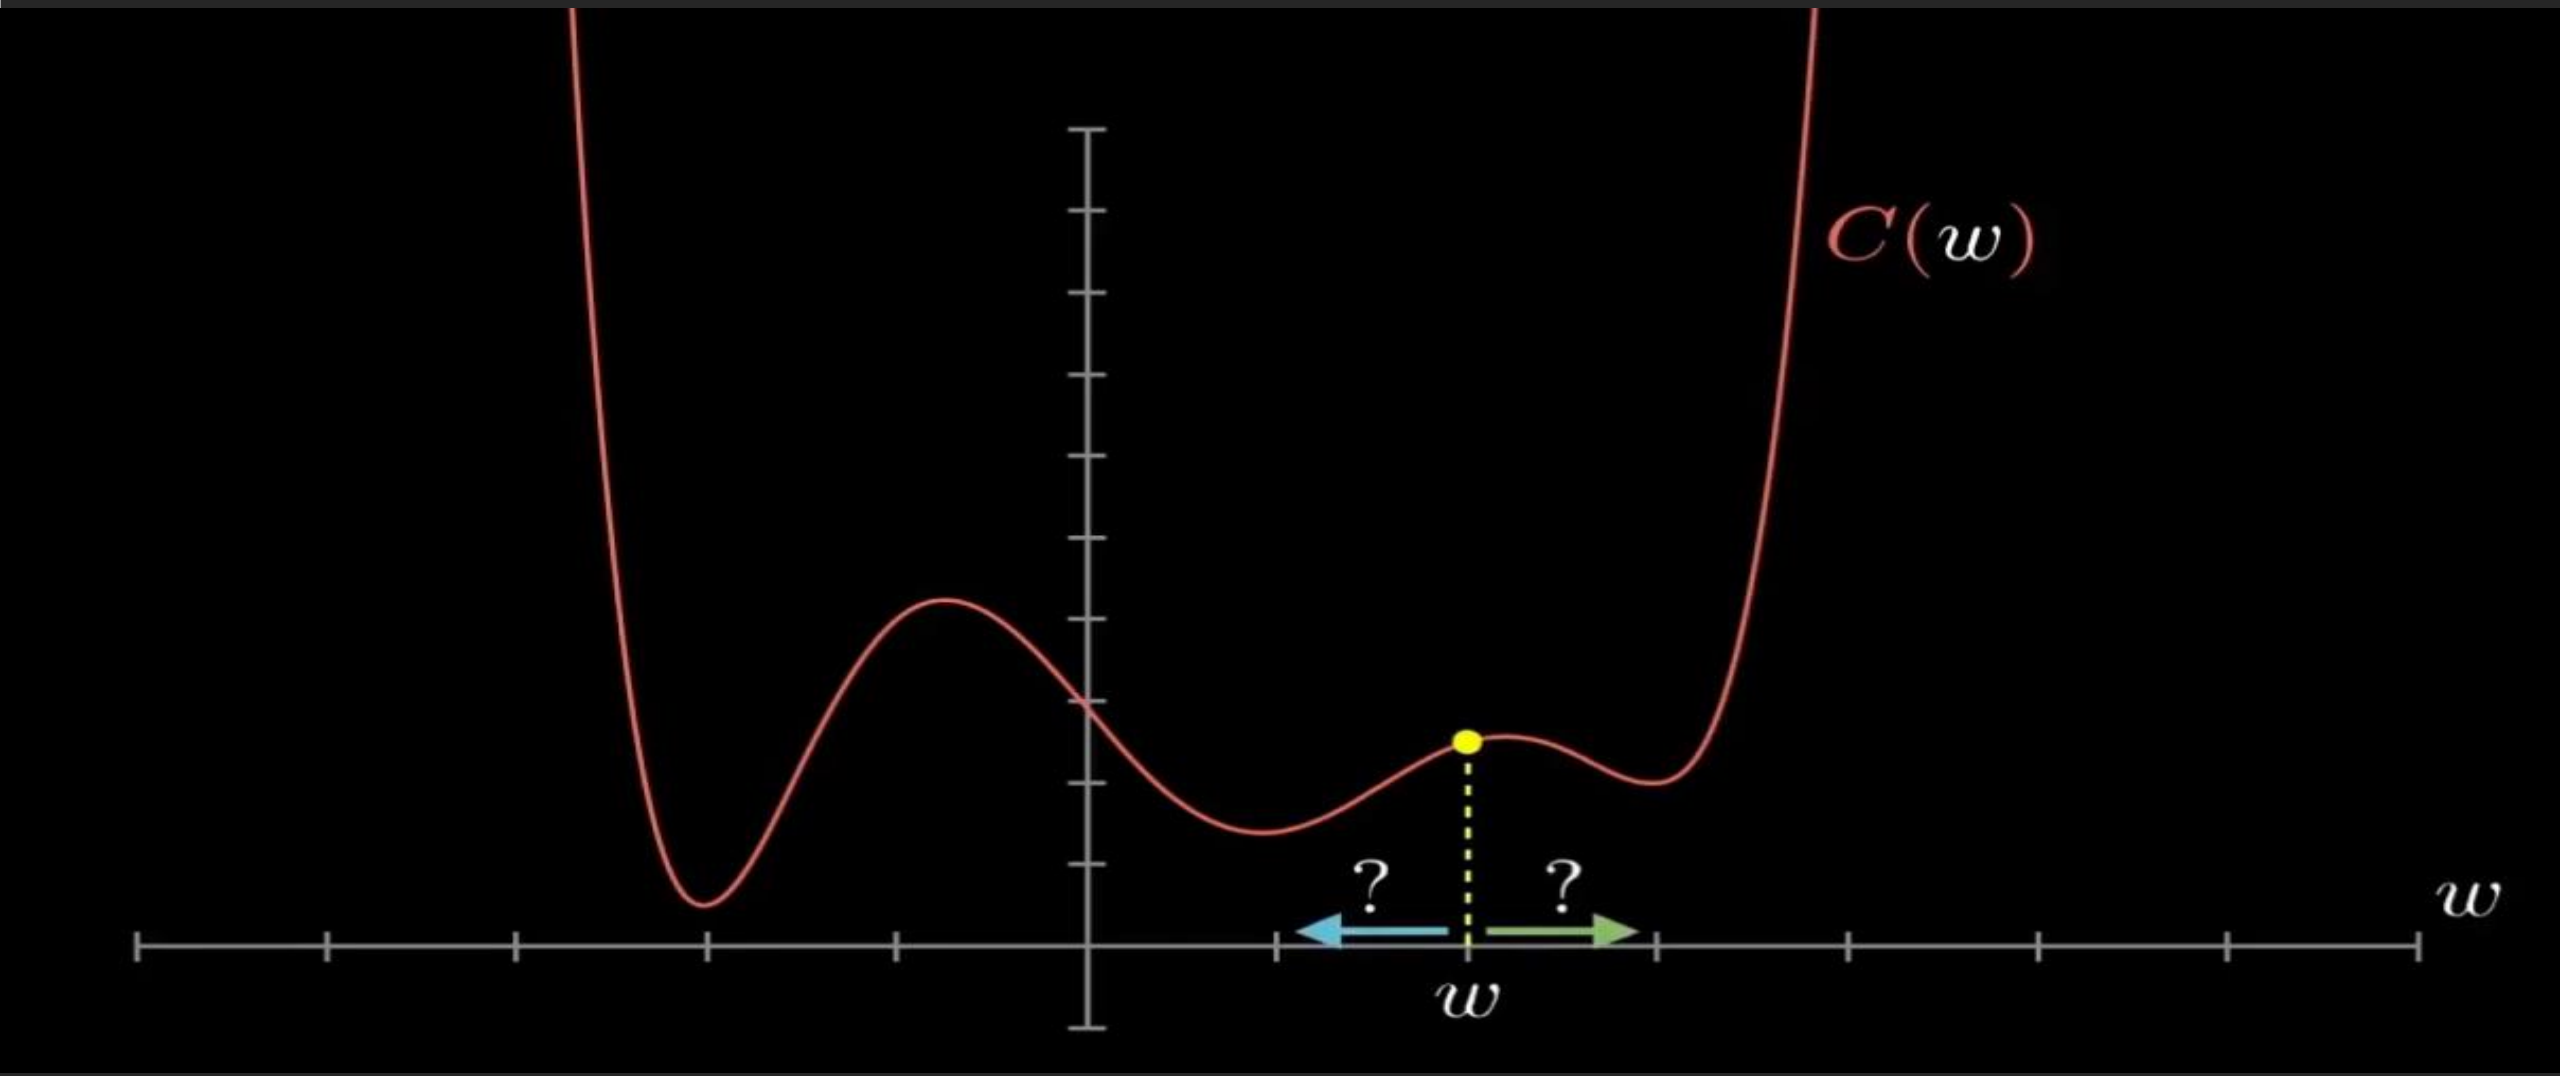

Dereceli alçalma
gradient decent?

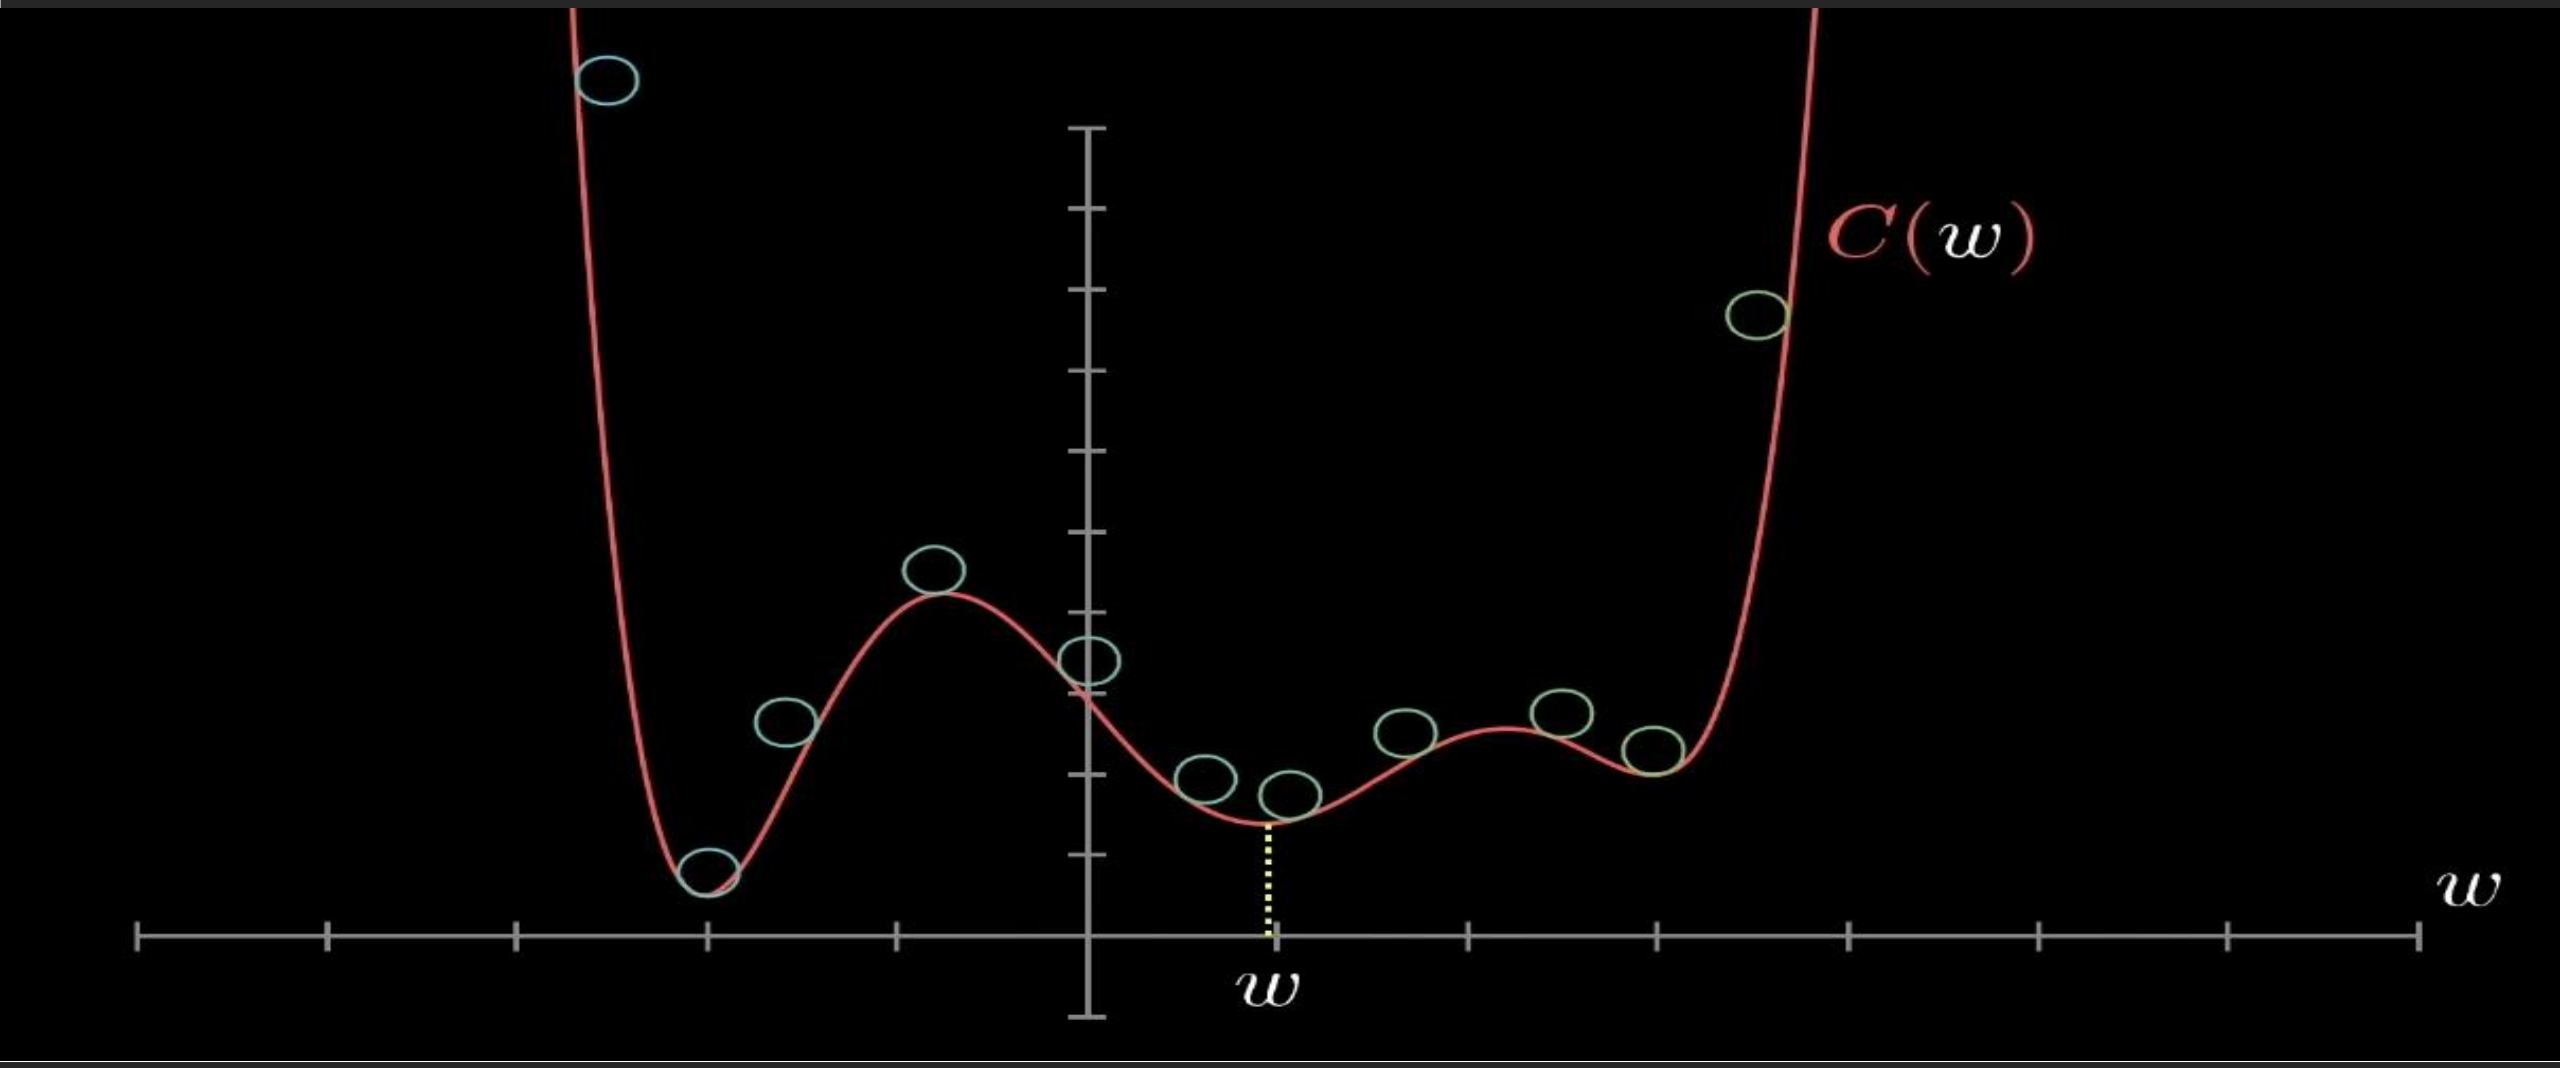

Dereceli alçalma
gradient decent?

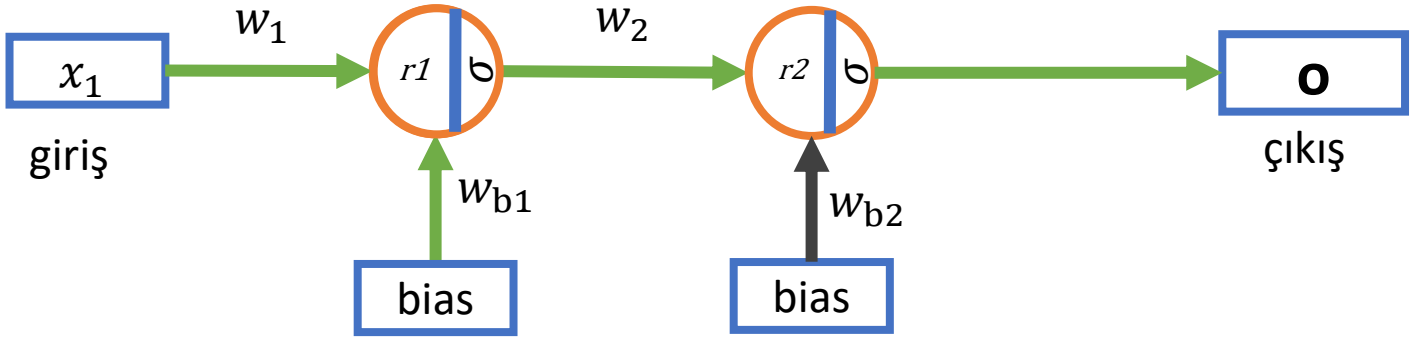

Arzu edilen çıkış

d

$$Hata = o - d$$

$$C_0 = (o - d)^2$$

Cost
maliyet

iteration
adım

Aktivasyon fonksiyonu

$$o = \sigma(\underbrace{n_1 \cdot \omega_2 + \omega_{b2}}_{r_2})$$

$$o = \sigma(r_2)$$

$$\frac{\partial C_0}{\partial \omega_2} = \frac{\partial r_2}{\partial \omega_2}\frac{\partial \sigma}{\partial r_2}\frac{\partial C_0}{\partial \sigma}$$

Zincir kuralı

$$C_0 = (o - d)^2 \quad | \quad o = \sigma(\underbrace{n_1 \cdot \omega_2 + \omega_{b2}}_{r_2}) \quad | \quad o = \sigma(r_2) \quad | \quad \frac{\partial C_0}{\partial \omega_2} = \frac{\partial r_2}{\partial \omega_2}\frac{\partial \sigma}{\partial r_2}\frac{\partial C_0}{\partial \sigma}$$

$$\frac{\partial C_0}{\partial \sigma} = 2 * (o - d)$$

$$\frac{\partial \sigma}{\partial r_2} = \sigma'(r_2)$$

$$\frac{\partial r_2}{\partial \omega_2} = n_1$$

$$\frac{\partial C_0}{\partial \omega_2} = (2 * (o - d)) * (\sigma'(r_2)) * (n_1)$$

$$\frac{1}{n}\sum_{i=1}^{n}\frac{\partial C_i}{\partial \omega_2}$$

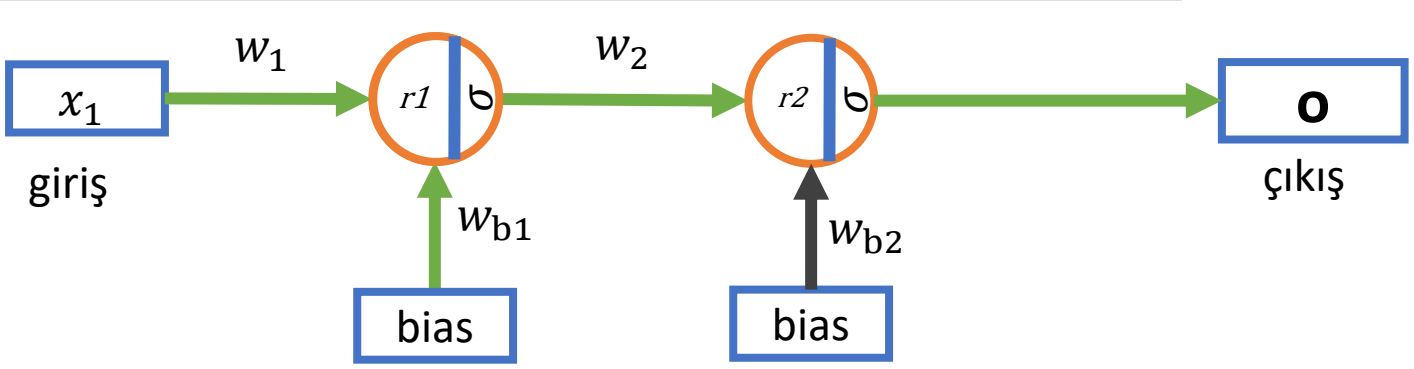

$$\nabla C^T = \left[\frac{\partial C}{\partial \omega_1}, \frac{\partial C}{\partial \omega_{b1}}, \frac{\partial C}{\partial w_2}, \frac{\partial C}{\partial \omega_{b2}}\right]$$

geri yayılım backpropagation

sıfırdan...
yapay Sinir ağları
artificial neural networks
from strach....

Mnist el yazısı rakamlar data seti

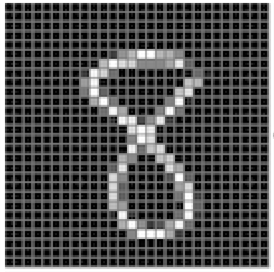

28 x 28
784 pixels

0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	4	62	146	182	254	254	181	176	139	15	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	34	186	253	217	208	136	136	136	166	232	99	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	61	242	208	111	3	0	0	0	0	0	18	32	107	43	0	0	0	0	0	0
0	0	0	0	0	0	0	0	156	242	23	0	0	0	0	0	0	0	13	191	181	6	0	0	0	0	0	0
0	0	0	0	0	0	0	0	121	255	98	3	0	0	0	0	0	8	194	225	12	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	169	253	120	3	0	0	0	0	128	247	51	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	3	111	244	169	19	0	14	131	249	117	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	59	241	235	72	142	229	66	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	25	218	254	231	36	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	133	253	221	33	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	19	237	111	196	217	19	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	174	138	0	23	193	204	18	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	96	224	0	0	0	25	218	169	3	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	215	138	0	0	0	0	86	253	99	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	215	97	0	0	0	0	3	162	214	11	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	215	97	0	0	0	0	0	118	253	68	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	185	157	0	0	0	0	0	40	254	98	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	50	244	61	0	0	0	0	112	244	58	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	174	251	142	59	83	167	244	111	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	6	133	253	253	253	169	61	3	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

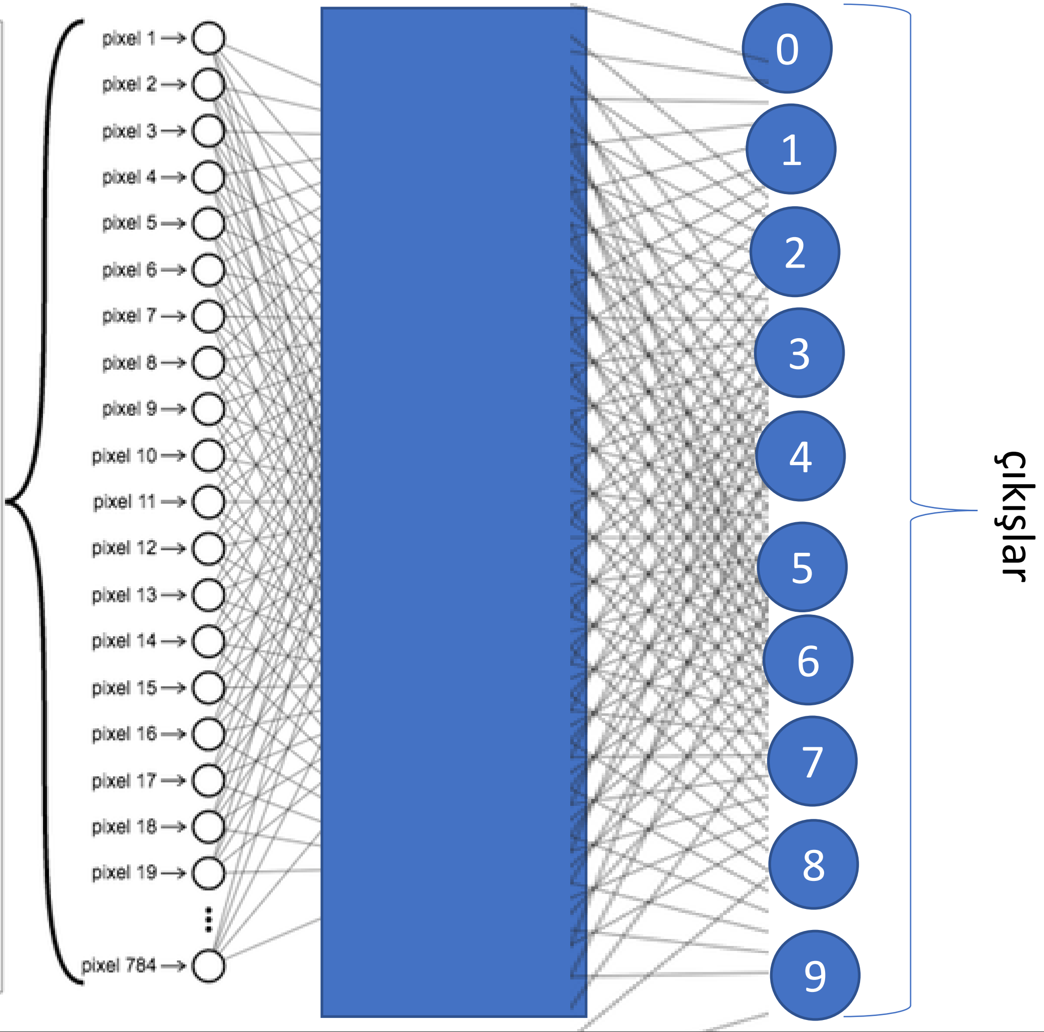

geri yayılım
back propagation ?

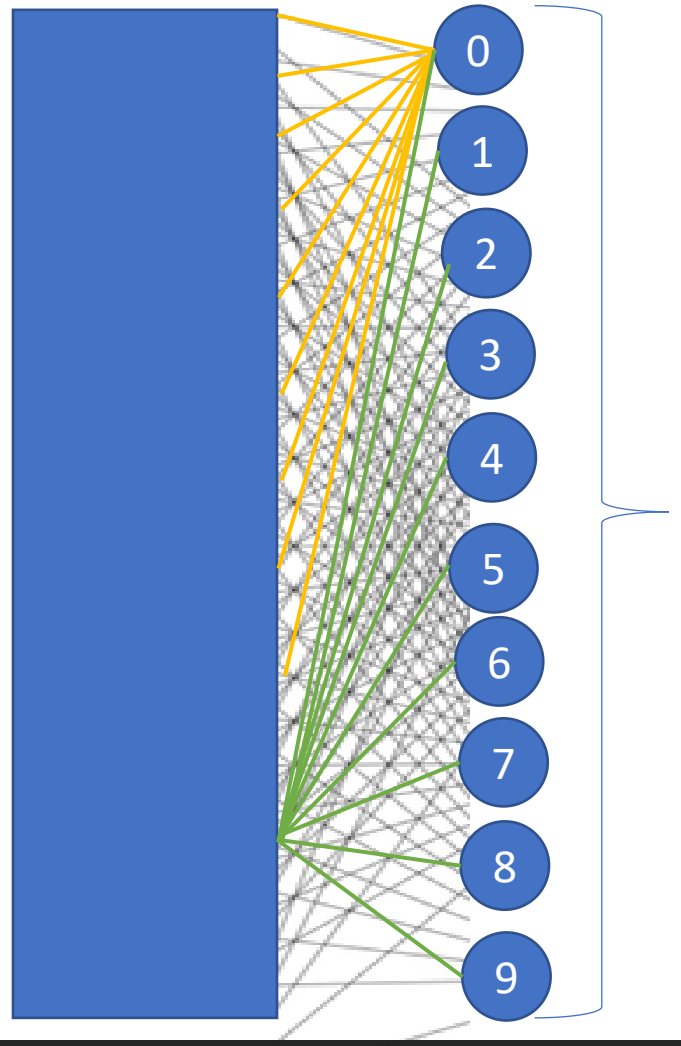

	0	1	2	3	4	5	6	7	8	9	
w1	↑	↑	↓	↑	↓	↑	↓	↓	↓	↑	↓
w2											
w3	↓	↓	↑	↓	↑	↓	↑	↑	↑	↓	↑
.											
.											
.											
.											
wn											

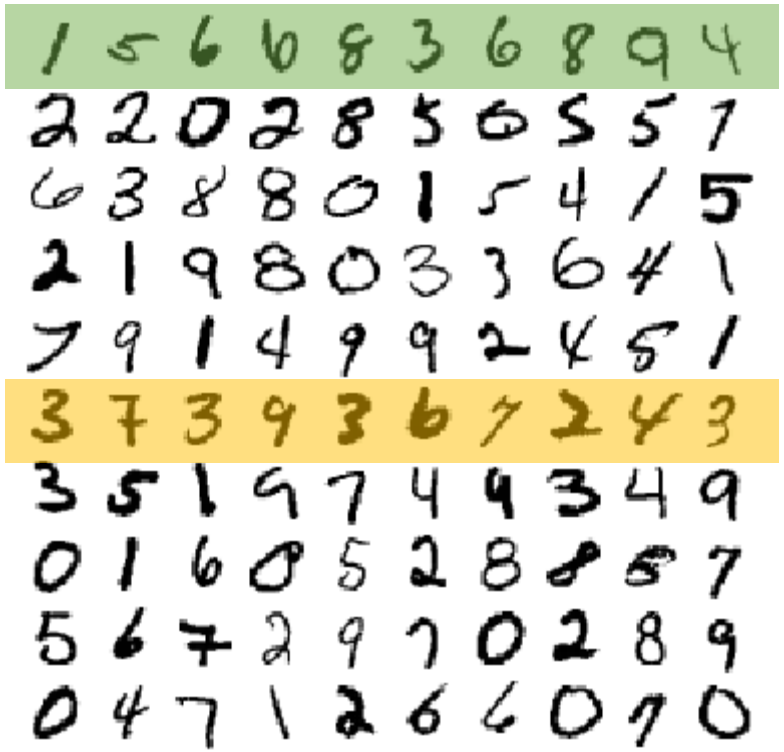

Mini-batch **Küçük grup**
Küçük yığın

1. Grup seç
2. Grubu YSA da işle
3. Küçük grubun ortalama gradyanını bul
4. Ağırlıkları bulunan ortalama gradyanla güncelle
5. Gruplar bitene kadar işleme devam devam et