

# Hafta 6

# Olasılık Yoğunluk Fonksiyonu



DeepLearning.AI

# Olasılık Dağılımları


---

## Olasılık Yoğunluk Fonksiyonu

# Olasılık Yoğunluk Fonksiyonu




Diyelimki çağrı merkezi 0 ile 5 dakika arasındaki herhangi bir zaman aralığında eşit olasılıkla cevap veriyor.



# Olasılık Yoğunluk Fonksiyonu




$P(2 \text{ ile } 3 \text{ dk. arasında olma olasılığı}) = ?$



# Olasılık Yoğunluk Fonksiyonu



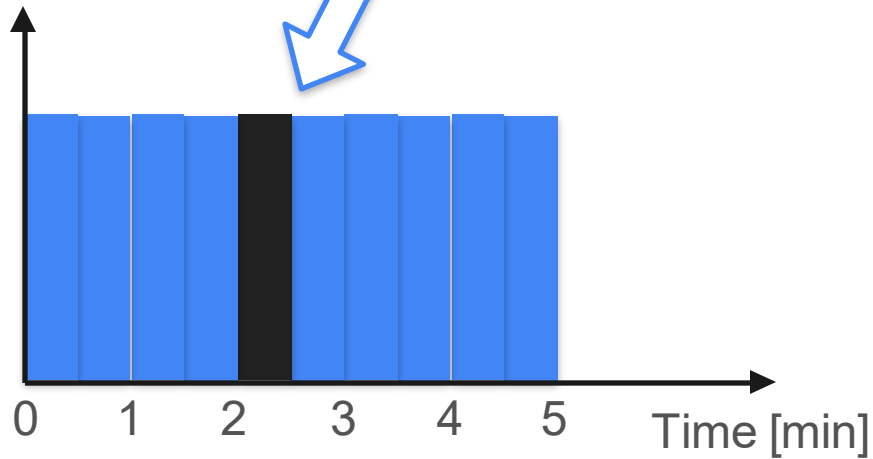
$$P(2 \text{ ile } 3 \text{ dk. arasında olma olasılığı}) = 1/5$$



# Olasılık Yoğunluk Fonksiyonu




$P(2 \text{ ile } 2.5 \text{ dk. arasında olma olasılığı}) = ?$



# Olasılık Yoğunluk Fonksiyonu



$$P(2 \text{ ile } 2.5 \text{ dk. arasında olma olasılığı}) = 0.1$$




Burada fark edebileceğiniz şey, dikdörtgenin yüksekliğinin hiç değişmediği, ancak genişliklerinin yarıya indirildiği ve bu nedenle olasılıkların da yarıya indiği görülmektedir.

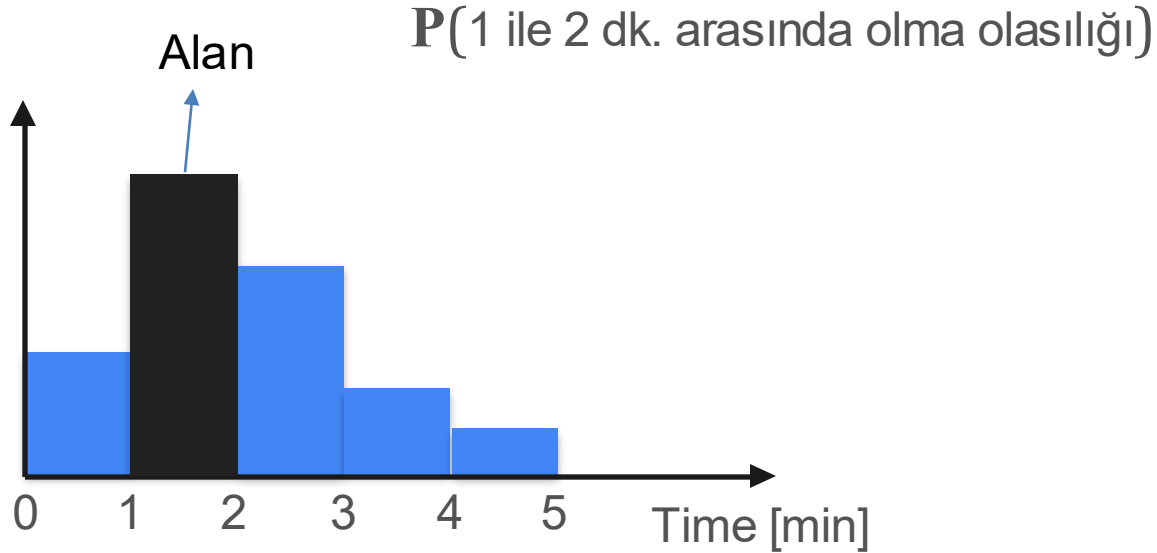
# Ayrıktan Sürekliye



$P(1 \text{ ile } 2 \text{ dk. arasında olma olasılığı}) = ?$




# Ayrıktan Sürekliye



# Ayrıktan Sürekliye



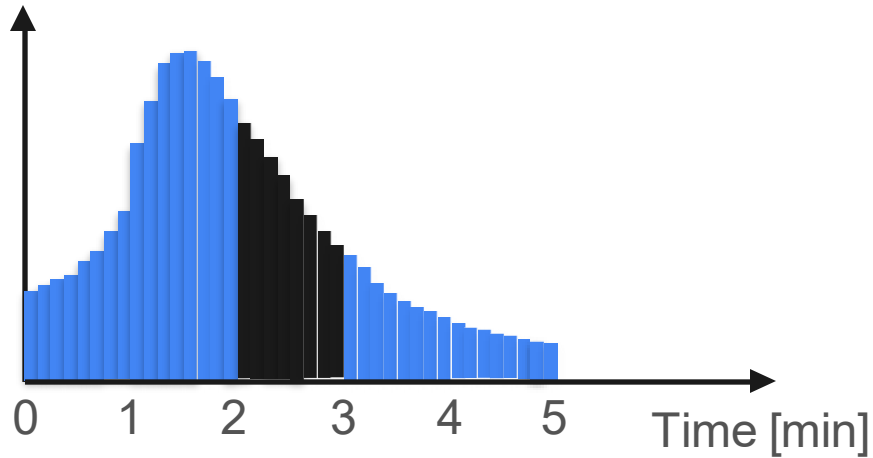
$P(1 \text{ ile } 1.30 \text{ dk. arasında olma olasılığı})$



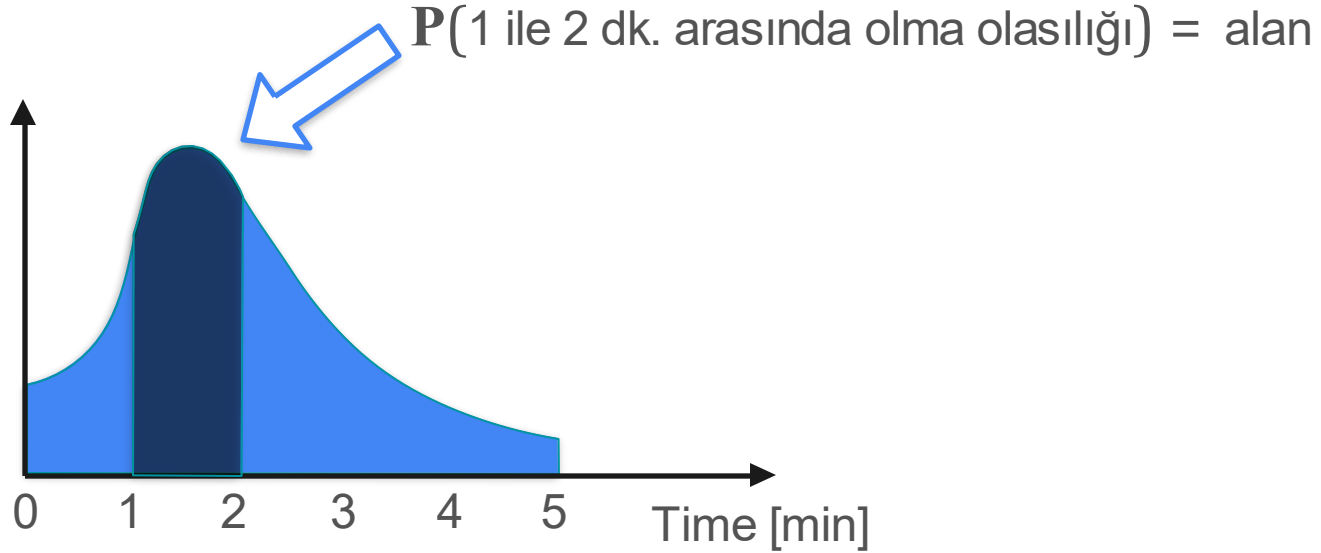
# Ayrıktan Sürekliye



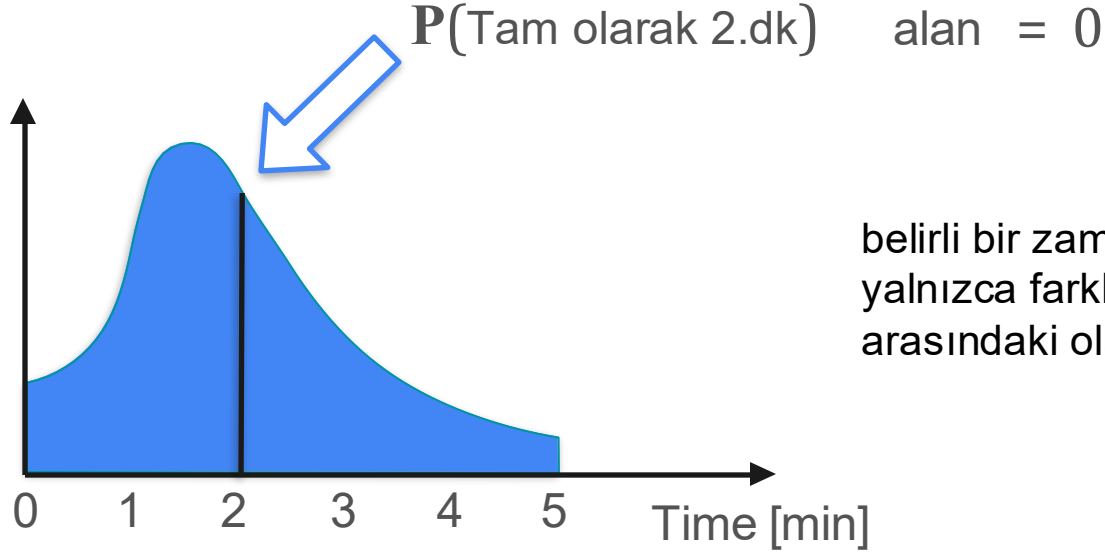
$P(2 \text{ ile } 3 \text{ dk. arasında olma olasılığı}) = \text{siyah alanların toplamı}$



# Ayrıktan Sürekliye







# Soru



belirli bir zaman değil,  
yalnızca farklı zaman pencereleri  
arasındaki olasılıkları düşünmeliyiz

# Ayrıktan Sürekliye

Özetlemek gerekirse, aralıkları küçüldükçe, alanlar da sıfıra gelene kadar küçülür. Bu yüzden sadece yüksekliklere değil aralıklara bakılması gerekir.



# Olasılık Yoğunluk Fonksiyonu : Tanım

Probability Density Function (PDF)  
(Olasılık Yoğunluk Fonksiyonu (PDF))

$$f_X(x)$$


Size her nokta etrafında olasılık biriktirme oranınızı söyler.

**Yalnızca sürekli değişkenler için tanımlıdır!**


$\mathbf{P}(a < X < b) = f_X(x)$ 'in altında kalan alan

$f_X(x)$  :

- Tüm sayılar için tanımlıdır
- $f_X(x) \geq 0$



# Olasılık Yoğunluk Fonksiyonu : Tanım



$$f_X(x)$$

Size her nokta etrafında olasılık biriktirme oranınızı söyler.


**Yalnızca sürekli değişkenler için tanımlıdır!**

$$f_X(x):$$

- Altında kalan alan  $f_X(x) = 1$

# Ayrık ve Sürekli Rastlantı Değişkenleri

## Ayrık rastlantı değişkenleri



Yalnızca sonlu veya en fazla sayılabilir sayıda değer alabilir

$$\text{PMF: } p_X(x) = \mathbf{P}(X = x)$$

## Sürekli rastlantı değişkenleri



Belirli bir aralıkta değer alır  
(sonsuz olasılıklar!)

$$\text{PDF: } f_X(x) \\ \mathbf{P}(X = x) = 0 \quad \forall x$$



DeepLearning.AI


# Olasılık Dağılımları

---

## Kümülatif Dağılım Fonksiyonu

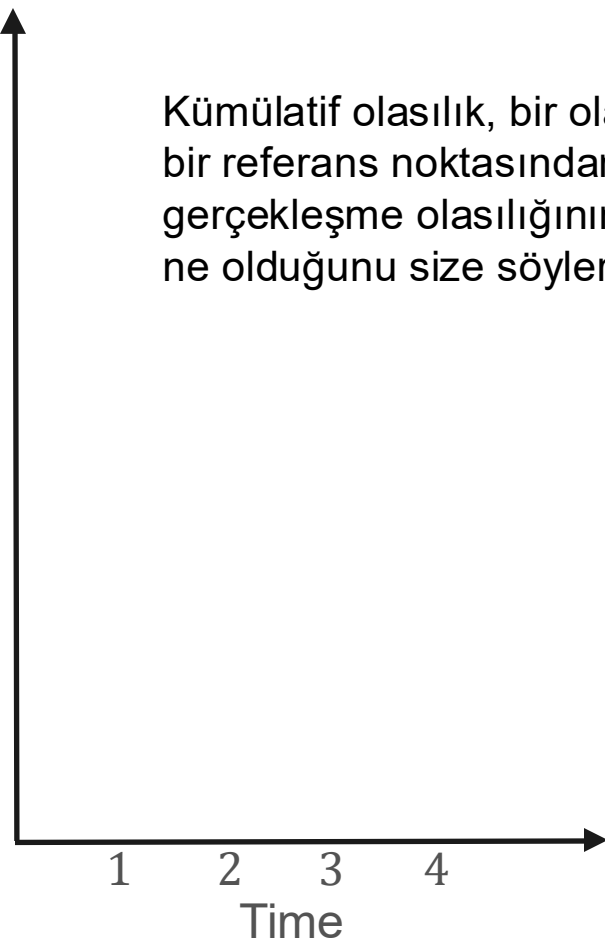
Kümülatif dağılım fonksiyonu, örneğin aramanın sıfır ile belirli bir dakika sayısı arasında olma olasılığını gösteren bir fonksiyondur ve hesaplanması çok daha kolaydır.

# Kümülatif Dağılım





Cumulative Probability

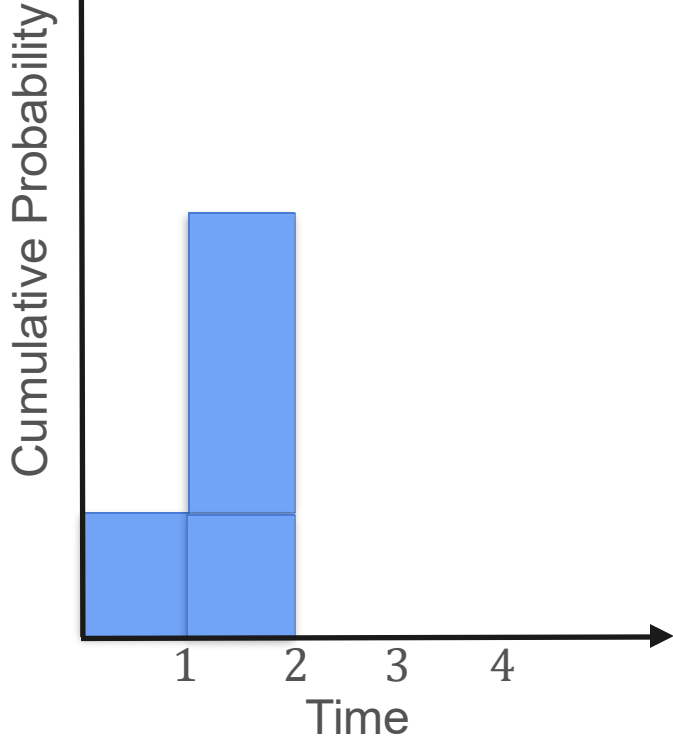

Kümülatif olasılık, bir olayın bir referans noktasından önce gerçekleşme olasılığının ne olduğunu size söyler.



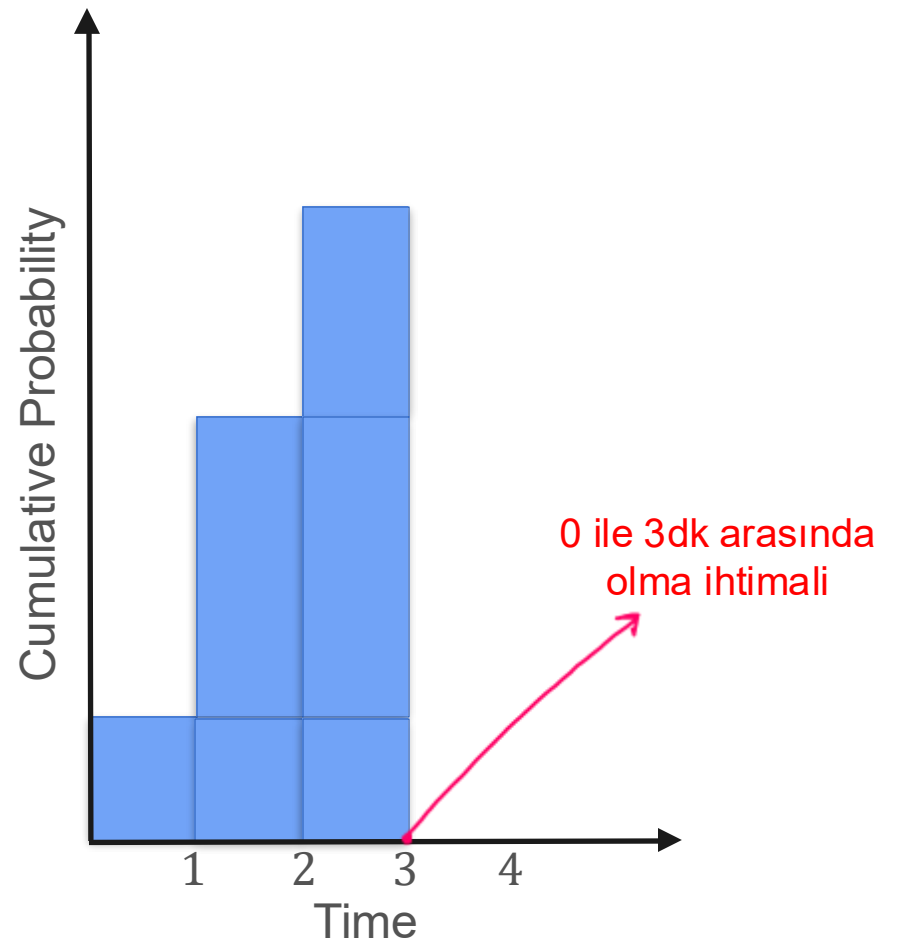

# Kümülatif Dağılım



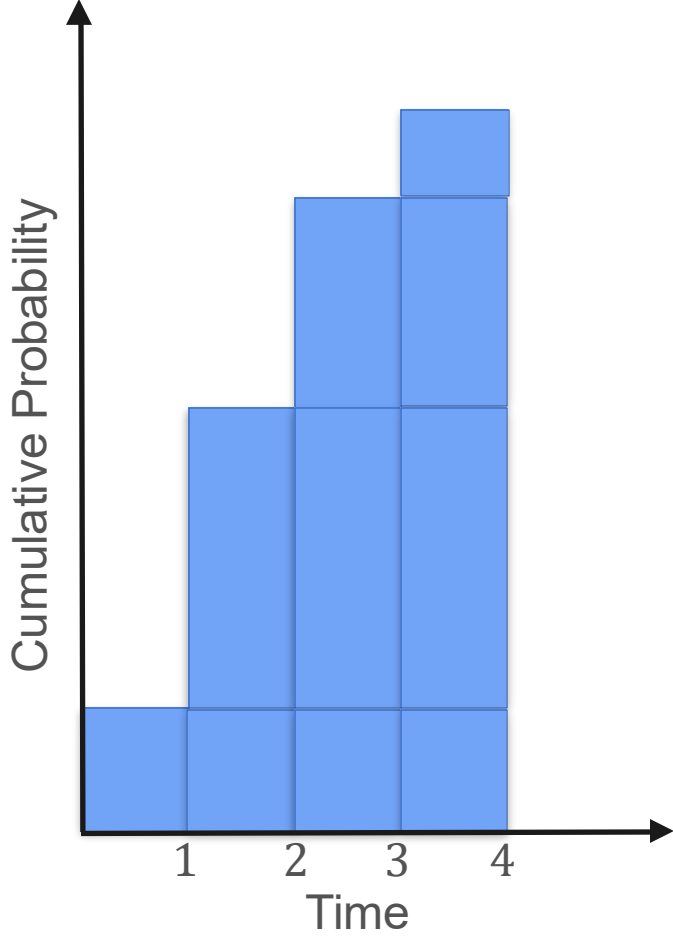

# Kümülatif Dağılım



# Kümülatif Dağılım



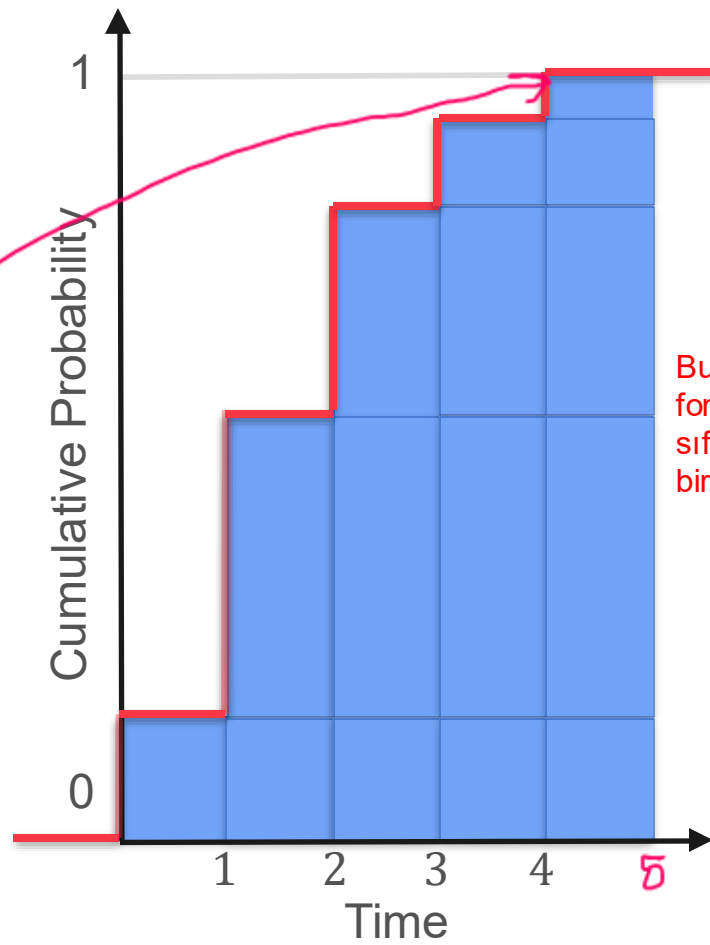
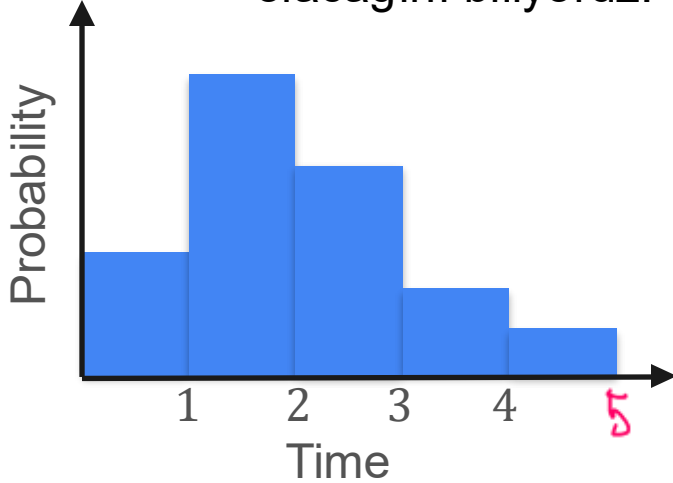
# Kümülatif Dağılım



# Kümülatif Dağılım




en sağdaki değer  
birdir, çünkü tüm  
aramaların beş  
dakika veya daha az  
olacağını biliyoruz.




Bu kümülatif dağılım  
fonksiyonu her zaman  
sıfırdan başlar ve  
birde biter.

# Kümülatif Dağılım

CDF: Kümülatif Dağılım Fonksiyonu




0'da alan = 0



Soldaki griften olasılıkları bulmak için alanları hesaplamamız gerekiyor ve sağdaki grafikte sadece yüksekliklere bakmamız gerekiyor.

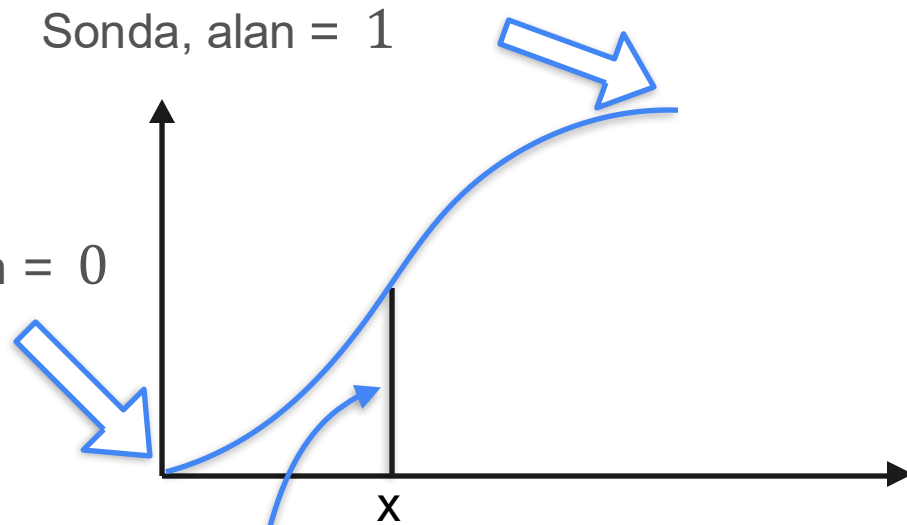
# Kümülatif Dağılım

CDF: CDF: Kümülatif Dağılım Fonksiyonu



0'da alan = 0

$$P(2 \text{ dakikadan az veya eşit}) = 0.5$$



Sonda, alan = 1

$$P(2 \text{ dakikadan az veya eşit}) = 0.5$$



CDF, rastgele bir deęişkenin belirli bir deęere kadar ne kadar olasılık biriktięini söyleyen bir fonksiyondur.

# Kümülatif Daęılım Fonksiyonu: Tanım

CDF, deęişkenin belirli bir deęere kadar birikmiş olasılığının ne kadar olduğunu gösterir.

Bu şü demek oluyor

$$\text{CDF}(x) = \mathbf{P}(X \leq x) \leftarrow \text{Her gerçek sayı için tanımlanır}$$



CDF aslında rastgele deęişkeninizin x'in bazı x deęerinden küçük veya ona eşit olma olasılığıdır


# Kümülatif Dağılım Fonksiyonu: Tanım

CDF, değişkenin belirli bir değere kadar birikmiş olasılığının ne kadar olduğunu gösterir.


Bu şu demek oluyor

$$F_X(x) = \mathbf{P}(X \leq x) \leftarrow \text{Her gerçek sayı için tanımlanır}$$

büyük F ile gösterilir.



Değişkeniniz soldaki gibi ayrık ve CDF'de sıçramalar olacaktır.





# Kümülatif Dağılım Fonksiyonu: Tanım

CDF, değişkenin belirli bir değere kadar birikmiş olasılığının ne kadar olduğunu gösterir.

Bu şu demek oluyor

$$F_X(x) = \mathbf{P}(X \leq x) \leftarrow \text{Her gerçak sayı için tanımlanır}$$




## Özellikler

- $0 \leq F_X(x) \leq 1$
- Sol “bitiş noktası” 0
- Sağ “bitiş noktası” 1
- Asla azalmaz


# PDF ve CDF Özet

PDF



- alan = 1
- Her zaman pozitif

CDF



- Sol “bitiş noktası” 0
- Sağ “bitiş noktası” 1
- (uç noktalar sonsuzda olabilir)
- Her zaman pozitif ve artan



DeepLearning.AI

# Olasılık Dağılımları

---

## Düzgün Dağılım

# Düzgün Dağılım: Motivasyon




Teknik destek hattını arıyorsunuz.  
Sıfır ile 15 dakika arasında istedikleri zaman cevap verebilirler ve bu süre içerisinde cevap vermezlerse hat kesilir.

# Düzensiz Dağılım: Motivasyon





Onları son 200 kez aradığınızda, yanıt vermelerinin ne kadar sürdüğünü not aldınız



Noktalar 0-15 dakika boyunca eşit olarak dağılmış gibi görünüyor.

# Düzensün Dağılım: Motivasyon

Bunun ölçümlere dayandığını unutmamalıyız, bu nedenle bir miktar sapma bekleniyor.



# Düzcün Dağılım: Motivasyon

T: beklemeniz gereken süre (dakika cinsinden)

0 ile 15 dakika arasındaki herhangi bir değerin aynı oluşma sıklığına sahip olması gerekir.




PDF, (0,15) aralığındaki tüm değerler için sabit olmalıdır



Hangi sabit?  $\rightarrow 15 \times h = 1 \rightarrow h = \frac{1}{15}$   
 $= 0.06$

Yoğunluk eğrisinin altındaki alanın 1 olması gerektiğini unutmayın




# Düztgün Dağılım: Model

Tüm olası deęerlerin bir aralıkta yer alması ve aynı oluşum sıklığına sahip olması durumunda, sürekli bir rastgele deęişken düztgün bir dağılımla modellenabilir.

Parametere:


- $a$ : başlangıç aralığı
- $b$ : bitiş aralığı

$$f_X(x) = \begin{cases} \frac{1}{b-a} & a < x < b \\ 0 & x \notin (a, b) \end{cases}$$




# Düzcün Dağılım: PDF


a, b aralığı PDF'den daha büyük olduğunda, PDF'nin yüksekliğinin daha küçük olduğunu ve aralık kısaldıkça hızla arttığını görebilirsiniz.




# Düzcün Dağılım: PDF





# Düztgün Dağılım: PDF



# Düzcün Dağılım: PDF





# Düzensün Dağılım: CDF



İlk önce 0'dan küçük bir  $x$ 'i düşünerek başlayalım. Bu durumda, PDF'nin altındaki alan soldan o noktaya kadar  $x$  noktasına kadar 0 olur. Bu nedenle, sıfırdan küçük herhangi bir değer için CDF 0'dır.



# Düzensün Dağılım: CDF

Şimdi, 0 ile 1 arasındaki herhangi bir  $x$ 'i alın.  
Değişkenin belirli bir  $x$ 'den daha küçük olma olasılığı buradaki alandır.




# Düzensün Dağılım: CDF


CDF, eğimi 1 olan bu çizgidir.





# Düzensün Dağılım: CDF



Son olarak, 1'den büyük herhangi bir  $x$  alırsanız, PDF'nin altındaki tüm alanı zaten toplamışsınızdır, bu nedenle olasılık 1 olarak kalır.



# Düzcün Dağılım: CDF





DeepLearning.AI

# Olasılık Dağılımları

---

## Normal Dağılım


$$p_X(x) = \binom{n}{x} p^x (1-p)^{n-x}$$

$$X \sim \text{Binom}(2, 0.5)$$

# Çok Büyük Binom Dağılımı



$$\binom{2}{1} (0.5)^1 \cdot (1-0.5)^{2-1}$$




Atış sayısı = 2

madeni paranın 2 kez atışındaki kafa sayısını ve olasılık kütle fonksiyonunu sayan binom dağılımı

# Çok Büyük Binom Dağılımı




Olasılık Kütle Fonksiyonu (PMF)




Atış sayısı = n

# Çok Büyük Binom Dağılımı




Atış sayısı = n

# Çok Büyük Binom Dağılımı




Atış sayısı = n

# Çok Büyük Binom Dağılımı



Atış sayısı = n

# Çok Büyük Binom Dağılımı




Atış sayısı =  $n$

**$n$  çok büyük olduğunda, binom dağılımının bir Gauss dağılımı ile oldukça iyi tahmin edilebileceği anlamına gelir**


# Çan Şekilli Veriler

$$e^{-\frac{x^2}{2}}$$



# Çan Şekilli Veriler

$$e^{-\frac{1}{2}(x-2)^2}$$




# Çan Şekilli Veriler

$$e^{-\frac{1}{2}\left(\frac{x-2}{3}\right)^2}$$

← Bell curve →

Data




# Çan Şekilli Veriler

$$\frac{1}{3\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-2}{3}\right)^2}$$

Bell curve

Data




# Çan Şekilli Veriler

$$\frac{1}{3\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-2}{3}\right)^2}$$

Bell curve

Area=1

Data



# Çan Şekilli Veriler

Mean =  $\mu$

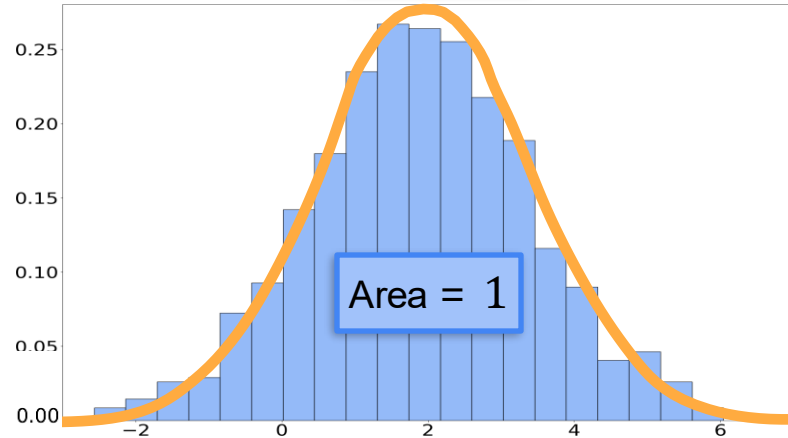
Standard deviation =  $\sigma$

$$\frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}$$

Bell curve

Area = 1

Data



# Normal Dağılım


Mean =  $\mu$

Standard deviation =  $\sigma$

$$\frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}$$

Bell curve

Area = 1




# Normal Dağılım

Parametere:

- $\mu$ : çanın merkezi
- $\sigma$ : çanın yayılımı

$$f_X(x) = \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{1}{2} \frac{(x-\mu)^2}{\sigma^2}}$$

ölçekleme sabiti



Aralık: tüm gerçek sayılar


Simetrik!

# Normal Dağılım

Parametere:

- $\mu$ : çanın merkezi
- $\sigma$ : çanın yayılımı

$$f_X(x) = \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{1}{2} \frac{(x-\mu)^2}{\sigma^2}}$$




# Normal Dağılım

Parametere:

- $\mu$ : çanın merkezi
- $\sigma$ : çanın yayılımı

$$f_X(x) = \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{1}{2} \frac{(x-\mu)^2}{\sigma^2}}$$




# Normal Dağılım

Parametere:

- $\mu$ : çanın merkezi
- $\sigma$ : çanın yayılımı

$$f_X(x) = \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{1}{2} \frac{(x-\mu)^2}{\sigma^2}}$$




# Normal Dağılım

Parametere:

- $\mu$ : çanın merkezi
- $\sigma$ : çanın yayılımı

$$f_X(x) = \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{1}{2} \frac{(x-\mu)^2}{\sigma^2}}$$




# Normal Dağılım - Gösterim

Parametere:

- $\mu$ : çanın merkezi
- $\sigma$ : çanın yayılımı

$$f_X(x) = \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{1}{2} \frac{(x-\mu)^2}{\sigma^2}}$$



$$X \sim \mathcal{N}(\mu, \sigma^2)$$


buna varyans denir

# Standart Normal Dağılım

Parameters:

- $\mu$ : 0
  - $\sigma$ : 1
- $$X \sim \mathcal{N}(0, 1^2)$$

$$\begin{aligned} f_X(x) &= \frac{1}{\sqrt{2\pi} \cdot 1} e^{-\frac{1}{2} \frac{(x-0)^2}{1^2}} \\ &= \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2} x^2} \end{aligned}$$



# Standardizasyon

Herhangi bir normal dağılımı standart olana dönüştürmenin gerçekten kolay bir yolu var!

$X$ , normal olarak dağıtılır ile:

$$\mu = 2, \sigma = 2.5$$

$$Z = \frac{X - \mu}{\sigma}$$

Farklı büyüklükteki değişkenleri karşılaştırmak için standardizasyon çok önemlidir!




# Standardizasyon

There's a really easy way to convert any normal distribution to the standard one!

$X$  distributes normally with  
 $\mu = 2, \sigma = 2.5$

$$X - 2$$




# Standardizasyon

There's a really easy way to convert any normal distribution to the standard one!

$X$  distributes normally with

$$\mu = 2, \sigma = 2.5$$

$$X - 2$$




# Standardizasyon

There's a really easy way to convert any normal distribution to the standard one!

$X$  distributes normally with  
 $\mu = 2, \sigma = 2.5$

$$X - 2$$




# Standardizasyon

There's a really easy way to convert any normal distribution to the standard one!

$X$  distributes normally with  
 $\mu = 2, \sigma = 2.5$

$$\frac{X - 2}{2.5}$$




# Standardizasyon

There's a really easy way to convert any normal distribution to the standard one!

$X$  distributes normally with  
 $\mu = 2, \sigma = 2.5$

$$\frac{X - 2}{2.5}$$




# Standardizasyon

There's a really easy way to convert any normal distribution to the standard one!

$X$  distributes normally with  
 $\mu = 2, \sigma = 2.5$

$$\frac{X - 2}{2.5}$$




# Standardizasyon

There's a really easy way to convert any normal distribution to the standard one!

$X$  distributes normally with  
 $\mu = 2, \sigma = 2.5$

$$\frac{X - 2}{2.5}$$




# Standardizasyon

There's a really easy way to convert any normal distribution to the standard one!

$X$  distributes normally with

$$\mu = 2, \sigma = 2.5$$

$$Z = \frac{X - 2}{2.5}$$



# Standardizasyon


There's a really easy way to convert any normal distribution to the standard one!

$X$  distributes normally with


$$\mu = 2, \sigma = 2.5$$

$$Z = \frac{X - \mu}{\sigma}$$



Standardization is crucial to compare variables of different magnitudes!




# CDF neye benziyor?




# CDF neye benziyor?



# CDF neye benziyor?




# CDF neye benziyor?



# PDF'den Olasılıkları Hesaplamak

Bu matematik elle yapılamaz




Eski günlerde insanlar veri tablolarını kullanıyordu



Artık eğrinin altında kalan alanı sizin için yaklaşık olarak hesaplamak için bazı yazılımların yardımını kullanabilirsiniz!

# Normal Dağılım: Uygulamalar



Boy



Kilo



IQ



Haberleşme kanalındaki  
gürültü

Genel olarak birçok bağımsız sürecin toplamı olan özellikler

ML'deki birçok model, değişkenlerin normal dağılıma uyduğu varsayımıyla tasarlanmıştır.




DeepLearning.AI

# Olasılık Dağılımları

---

## Bir Dağılımdan Örnekleme


# Bir Dağılımdan Örnekleme



Diyelimki renklerimiz basit bir ayrık dağılımına sahiptir, üç olası sonuç yeşil, mavi ve turuncu



şimdi bu dağılımı takip eden rastgele bir veri örneği oluşturmak istediğiniz bir deney çalıştırmak istiyorsunuz. Peki bu dağılımdan verileri nasıl örnekleyebilirsiniz?

# Bir Dağılımdan Örnekleme






- **Adım 1:** 0 ile 1 arasında rastgele bir sayı üretin
- **Adım 2:** sayının hangi aralığa ait olduğunu bulun
  - $[0, 0.3)$
  - $[0.3, 0.8)$
  - $[0.8, 1]$
- **Adım 3:** Aralığa göre bir sonuç atayın

# Bir Dağılımdan Örnekleme






- **Adım 1:** 0 ile 1 arasında rastgele bir sayı üretin
- **Adım 2:** sayının hangi aralığa ait olduğunu bulun
  - $[0, 0.3)$
  - $[0.3, 0.8)$
  - $[0.8, 1]$
- **Adım 3:** Aralığa göre bir sonuç atayın



# Bir Dağılımdan Örnekleme



# Bir Dağılımdan Örnekleme





# Bir Dağılımdan Örnekleme



Diyelim ki soldaki Gauss dağılımına sahip olduğunuzda, bu dağılımdan rastgele seçmek istersiniz. Kolay değil çünkü alanları hesaplamak zor.

# Normal Dağılımdan Örneklenme

Ama sağdaki CDF'ye bakarsanız ve o gri aralıktan eşit olarak seçersiniz.



Dolayısıyla CDF, hem ayrık hem de sürekli durum için, belirli bir dağılımdan örneklenme yapmak istediğinizde çok kullanışlı bir yöntemdir.

# Normal Dağılımdan Örnekleme

