

Eskişehir Osmangazi Üniversitesi  
Fen Bilimleri Enstitüsü  
İnşaat Mühendisliği Anabilim Dalı



# KESİKLİ TERCİH MODELLERİ

## Discrete Choice Models

---

*Dr. Kadir Berkhan AKALIN*

3

# İSTATİSTİKSEL ANALİZ YÖNTEMLERİ

Toplanan verilerin anlamlandırılması ve açıklanması amacıyla kullanılan yöntemlerdir.



BETİMSEL İSTATİSTİK		ÇIKARIMSAL İSTATİSTİK	
KAPSAM	AMAÇ	KAPSAM	AMAÇ
VERİ DÜZENLEME	VERİNİN AÇIKLANMASI	TAHMİN	ANAKÜTLE KARAKTERİSTİKLERİ HAKKINDA KARAR VERME
VERİ TANITIMI		HİPOTEZ TESTİ	
VERİ KARAKTERİZASYONU			

## OLASILIK (PROBABILITY)

Her olaya 0 ile 1 arasında bir gerçel sayı tahsis eden bir fonksiyondur. Olasılık fonksiyonunun belirtildiği örnek uzaya olasılık uzayı denir. Evrensel sonuç kümesinin (anakütle) sonlu olduğunu, her sonucun meydana gelme olasılığının eşit olduğunu ve birbirini dışladığı (bir zarın atılması gibi) varsayımında A sonucuyla sonuçlanması muhtemel olan n olası sonuç ve m durum kümesi göz önüne alındığında, A sonucunun olma olasılığı aşağıdaki gibi hesaplanır:

$$P(A) = \frac{m}{n}$$

## OLASILIK (PROBABILITY)

Örnek 1: 6 yüzlü bir zarın 3 gelme olasılığı

$m = \{3\}$  (3 gelmesi durumu)

$n = \{1,2,3,4,5,6\}$  (olası sonuçlar kümesi)

$$P(3) = \frac{1}{6}$$


Örnek 2: 6 yüzlü bir zarın tek sayı gelme olasılığı

$m = \{1,3,5\}$  (tek sayı gelmesi durumu)

$n = \{1,2,3,4,5,6\}$  (olası sonuçlar kümesi)

$$P(\text{tek\_sayı}) = \frac{3}{6}$$

Yolculuk Süresi (dk)	Frekans	Bağıl Frekans (P)
$0 \leq X \leq 10$	10	$10/80 = 0.125$
$10 < X \leq 20$	18	$18/80 = 0.225$
$20 < X \leq 30$	22	$22/80 = 0.275$
$30 < X \leq 40$	12	$12/80 = 0.150$
$40 < X \leq 50$	10	$10/80 = 0.125$
$50 < X \leq 60$	8	$8/80 = 0.100$
<b>Toplam</b>	<b>80</b>	<b>1.000</b>



Sonuçlar kümesi sonlu değilse veya herhangi iki sonucun meydana gelme olasılığı eşit değilse, o zaman bağıl frekansları olasılık olarak düşünebiliriz.

## RASSAL DEĞİŞKEN (RANDOM VARIABLE)

Değerleri rassal olan ve bu değerler için bir olasılık dağılımı saptama imkânı olan, yani, belirli değerleri belirli olasılıklarla alan değişkendir.

Diğer bir deyişle, bir örnek uzaydaki her rastgele olaya sayısal bir değer atayan bir fonksiyondur. Rasgele değişken gibi büyük harflerle gösterilir. Rastgele değişkenler kesikli rastgele ve sürekli rastgele olmak üzere ikiye ayrılır:

Bir rastgele değişkeninin olası değerlerinin sayısı sonlu veya sayılabilir ise **Sürekli Rassal Değişken**, bir rastgele değişkeninin olası değerleri bir aralıktan yada aralıklar kümesinden oluşuyor ise **Kesikli Rassal Değişken** olarak ifade edilir.

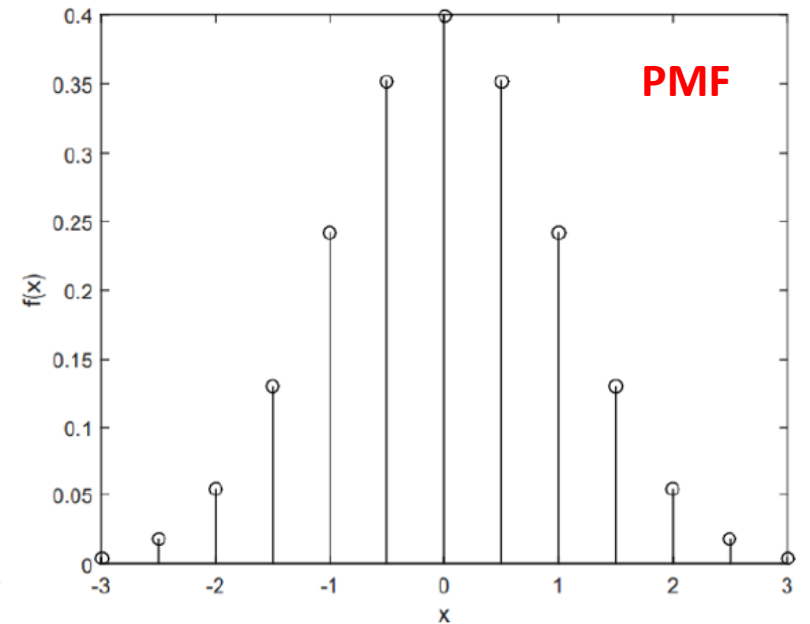

## **OLASILIK DAĞILIMI (PROBABILITY DISTRIBUTION)**

Bir deney için farklı olası sonuçların ortaya çıkma olasılıklarını veren matematiksel fonksiyondur. Bir olasılık dağılımı bir rassal olayın ortaya çıkabilmesi için değerleri ve olasılıkları tanımlar. Değerler olay için mümkün olan tüm sonuçları kapsamalıdır ve olasılıkların toplamı bire eşit olmalıdır.



# OLASILIK KÜTLE FONKSİYONU VE OLASILIK YOĞUNLUK FONKSİYONU

Olasılık kütle fonksiyonu (probability mass function –PMF) ve olasılık yoğunluk fonksiyonu (probability density function –PDF), sırasıyla kesikli ve sürekli olasılık dağılımlarını tanımlamak için kullanılır. Bir gözlemin tam olarak bir hedef değere eşit (ayrık) veya hedef değer etrafında bir aralık içinde (sürekli) olma olasılığının belirlenmesini sağlar.



# OLASILIK KÜTLE FONKSİYONU (PMF)

Kesikli Rassal Değişken


$X$  kesikli bir rastgele değişken olduğunda;

$f_X(x) = P(X = x)$  fonksiyonu rastgele değişkenin olasılık fonksiyonu veya olasılık kütle fonksiyonudur.

Olasılık fonksiyonu aşağıdaki koşulları sağlamalıdır:

$$f_X(x) \geq 0$$

$$\sum_x f_X(x) = 1$$



# OLASILIK YOĞUNLUK FONKSİYONU (PDF)

Sürekli Rassal Değişken


$X$  sürekli bir rasgele değişken olduğunda;

$P(a < X < b) = P(a \leq X \leq b) = \int_a^b f(x)dx$  fonksiyonu rastgele değişkenin olasılık fonksiyonu veya olasılık kütle fonksiyonudur.

Olasılık yoğunluk fonksiyonu aşağıdaki koşulları sağlamalıdır:

$$f_X(x) \geq 0$$

$$\int_{-\infty}^{+\infty} f_X(x)dx = 1$$



## **BEKLENEN DEĞER (EXPECTED VALUE)**

Kesikli Rassal Değişken

Beklenen değer, ortaya çıkan olasılık dağılımından beklenen değeri sağlar ve her değer, o değeri elde etme olasılığıyla çarpılması ve olası tüm sonuçların toplanmasıyla hesaplanır:

$$E(X) = \sum_x x f_X(x)$$

$$E(X) = \mu = \sum_i p(x_i) x_i$$

## **BEKLENEN DEĞER (EXPECTED VALUE)**

Sürekli Rassal Değişken

Sürekli bir değişken için beklenen değeri kesikli bir değişken gibi hesaplayabiliriz, tüm aralık için eğrinin altındaki alanı hesaplamak için aralık boyunca toplamı bir integrale değiştirebiliriz.

$$E(X) = \int_{-\infty}^{+\infty} xf(x)dx$$

$$E(X) = \mu = \int_{-\infty}^{+\infty} p(x)x dx$$

## BEKLENEN DEĞER (EXPECTED VALUE)

Özetle,

Bir rastgele değişkenin (X) beklenen değeri,  $E(X)$ , rastgele değişkenin alabileceği değerler kümesinin ortalamasıdır.

Örnek 3: İdeal bir 6 yüzlü bir zarın herhangi bir yüzünün gelme olasılığı  $1/6=0,167$  olduğuna göre;

Beklenen değeri:

$$E(X) = 1 \frac{1}{6} + 2 \frac{1}{6} + 3 \frac{1}{6} + 4 \frac{1}{6} + 5 \frac{1}{6} + 6 \frac{1}{6} = 3.5$$

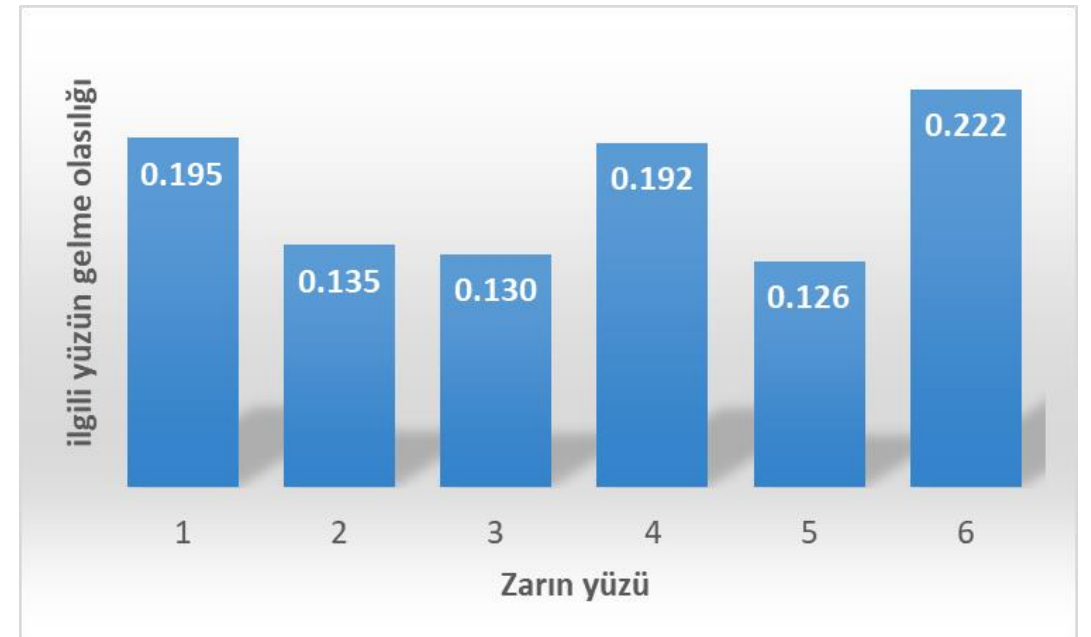


## BEKLENEN DEĞER (EXPECTED VALUE)

Örnek 4: 1000 kez atılmış 6 yüzlü bir zarın gözlemlerine ait dağılım verildiğine göre;

- Beklenen değeri:

$$\begin{aligned} E(X) &= 1 * 0.195 + 2 * 0.135 + 3 * 0.130 + 4 \\ &* 0.192 + 5 * 0.126 + 6 * 0.222 = 3.585 \end{aligned}$$



## VARYANS (VARIANCE)

Belirli bir veri noktası için model tahmininin deęişkenlięi veya verilerin nasıl yayıldığını bize gösteren deęerdir. Analizcinin gözlemlerin ortalama etrafında ne kadar daęınık veya yayılmış olduğunu anlamasını sağlar.

$$E((X - \mu)^2) = \sigma^2 = \sum_i p(x_i)(x_i - \mu)^2 \quad \text{Kesikli Rassal Deęişken}$$

$$E((X - \mu)^2) = \sigma^2 = \int_{-\infty}^{+\infty} p(x)(x - \mu)^2 dx \quad \text{Sürekli Rassal Deęişken}$$

$\sigma$ : Standart sapma

$\mu$ : Ortalama



## **YANLILIK (BIAS)**

Modelleme sonucunda tahmin edilen veriler ile gerek veriler arasındaki uzaklıđı yansıtan deđerdir.

## **EĐİTİM VE TEST VERİ SETİ (TRAIN AND TEST DATA SET)**

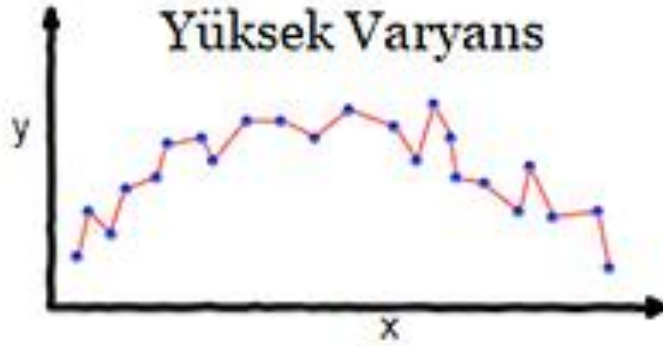
Veri setinde modelin kurulduđu kısmına eđitim veri seti, kurulan modelin dođruluđunun ve nasıl alıřtıđını gözlemlenmesi için ayrılan veriye test veri seti denir.

## **AŞIRI ÖĞRENME (OVERFITTING)**

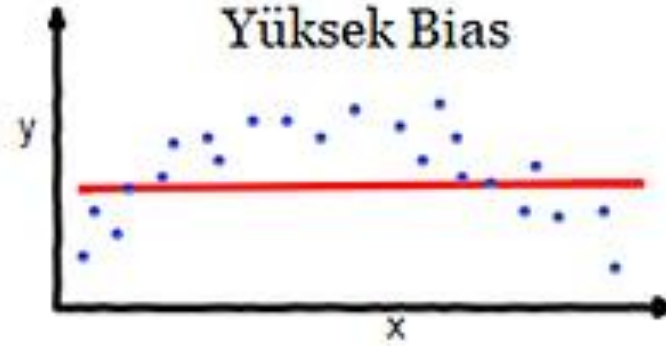
Bir modelin eğitim verisiyle tam uyum göstermeye zorlanması sebebiyle test (veya senaryo) verilerini iyi tahmin edememesi durumudur.

## **EKSİK ÖĞRENME (UNDERFITTING)**

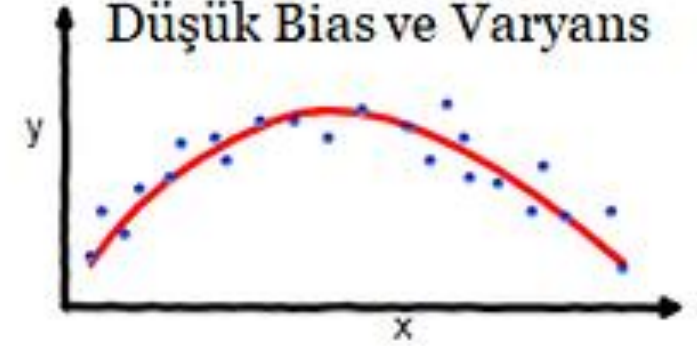
Eğitim veri setinde model eğitilirken sonuçların doğruluğunun düşük çıktığı ve doğal olarak test (veya senaryo) verilerinin doğru tahmin edilemeyeceği durumudur.



Overfitting

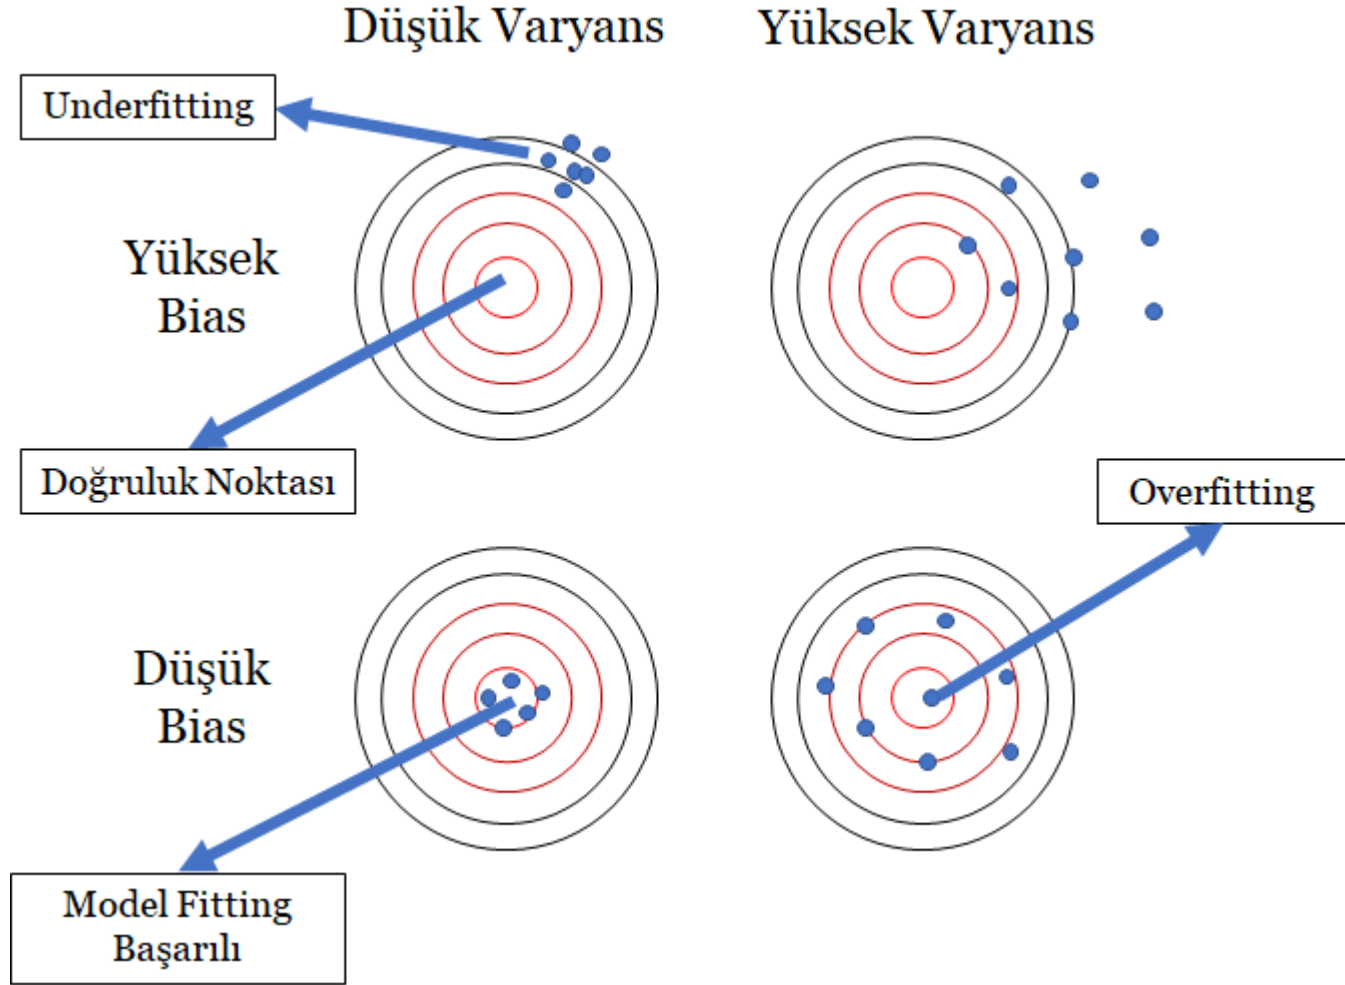


Underfitting



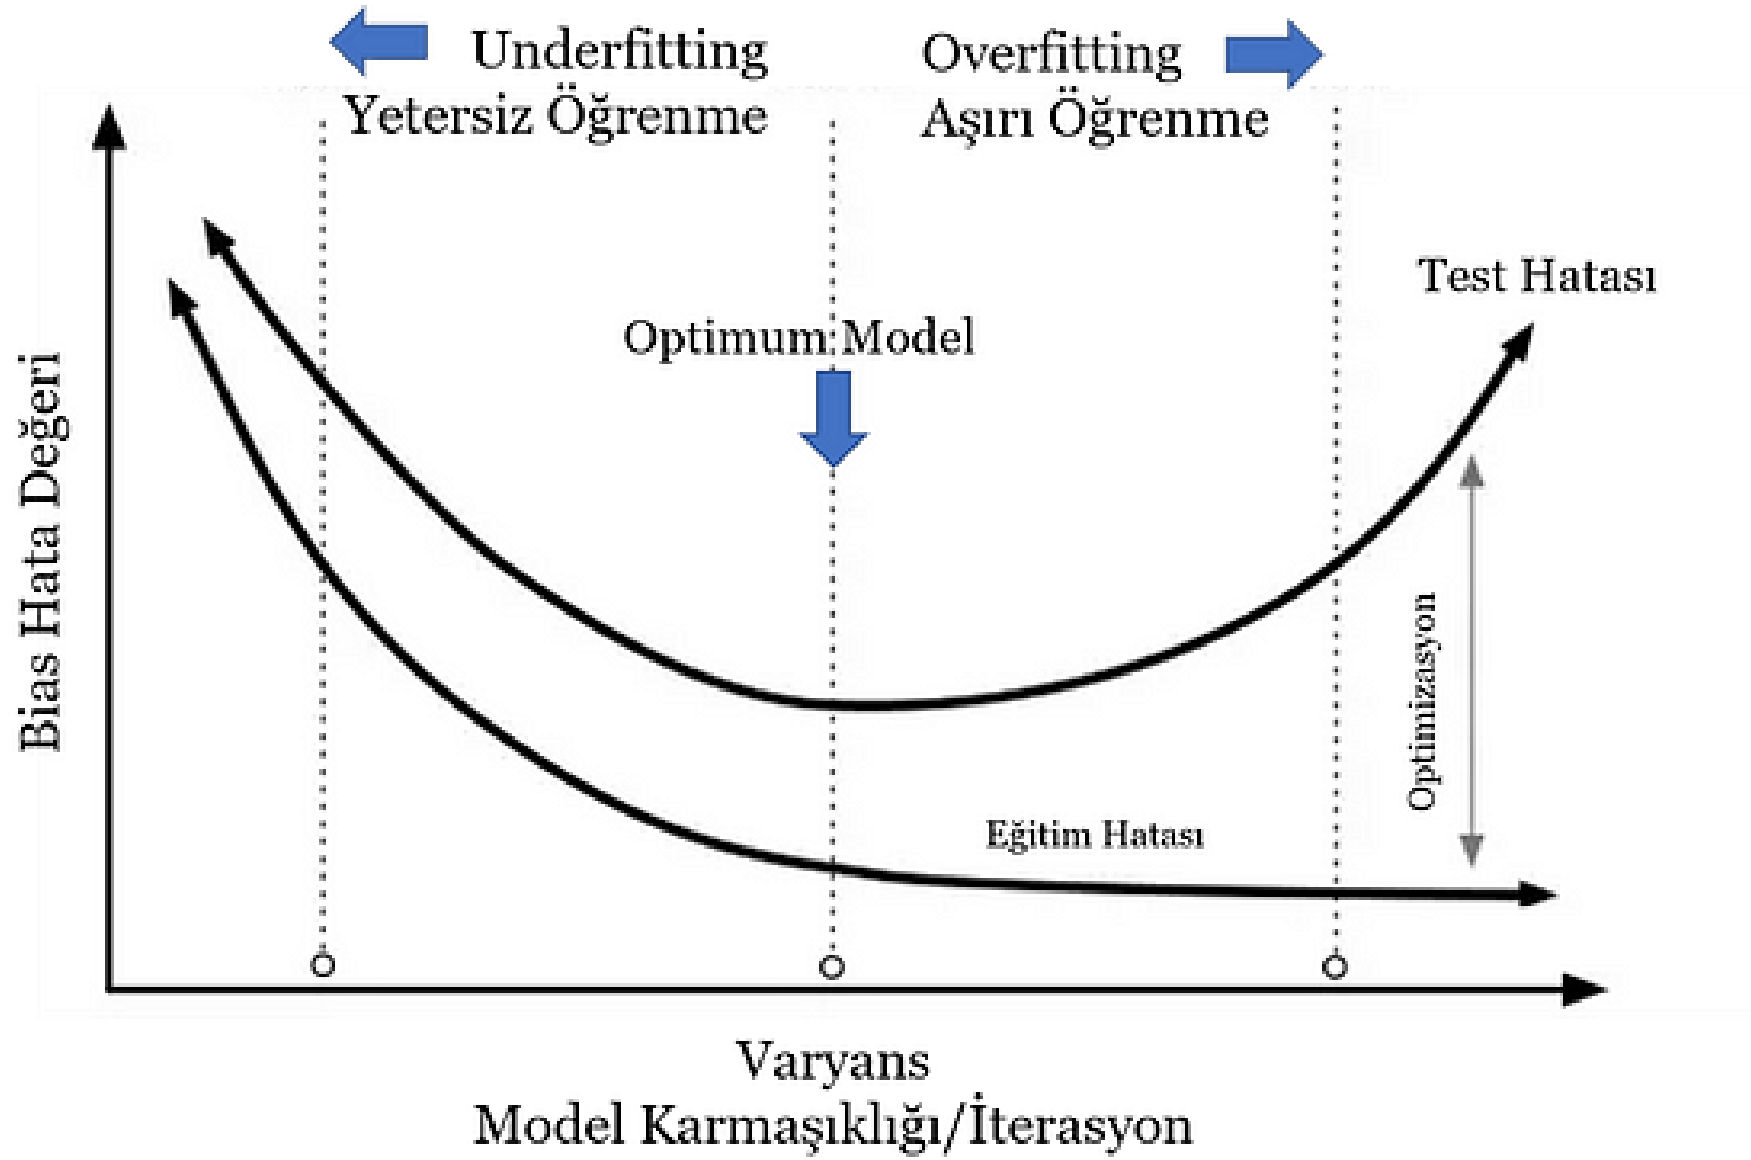
Model Uyumlu  
Dengeli Tahmin

# VARYANS ve YANLILIK



## Bazı Çözüm Yöntemleri:

- Çapraz geçerleme (Cross validation)
- Veri ekleme (Row insertion)
- Değişken seçimi (Feature selection)
- Budama (Trim)
- Düzenleştirme (Regularization)



## KOVARYANS (COVARIANCE)

İki rastgele değişkenin birlikte değişme derecesini temsil eden istatistiksel bir ölçüdür. Bir kovaryans istatistiğinin işareti, iki rastgele değişken arasındaki ilişkinin yönünü gösterir, ancak büyüklüğü, ilişkinin gücünü temsil etmesi açısından genellikle bilgilendirici değildir.

$$\text{Cov}(x_1, x_2) = E((x_1 - \mu_1)(x_2 - \mu_2))$$

İki rastgele değişkenin olduğu bir durum için;

$$E(x_1 + x_2) = E(x_1) + E(x_2) = \mu_1 + \mu_2$$

$$Var(x_1 + x_2) = Var(x_1) + Var(x_2) + 2Cov(x_1, x_2)$$

Burada;  $Cov(x_1, x_2) = E((x_1 - \mu_1)(x_2 - \mu_2))$  olduğuna göre;

$$E(x_1 + x_2) = E(x_1) + E(x_2) = \mu_1 + \mu_2$$

$$Var(x_1 + x_2) = Var(x_1) + Var(x_2) + 2E((x_1 - \mu_1)(x_2 - \mu_2))$$

olacaktır.

## Örnek 5: Bir zar atılması durumu

$X_1$	$f(X_1)$	$X_1 f(X_1)$		$(X_1 - \mu)^2$	$(X_1 - \mu)^2 f(X_1)$
1	0.167	0.167		6.250	1.042
2	0.167	0.333		2.250	0.375
3	0.167	0.500		0.250	0.042
4	0.167	0.667		0.250	0.042
5	0.167	0.833		2.250	0.375
6	0.167	1.000		6.250	1.042
Beklenen Değer, $E(X_1) =$ $(\mu)$		3.500		Varyans, $Var =$	2.917
				Standart Sapma, $\sigma =$	1.708



## Örnek 6: İki ayrı zar atılması durumu için kovaryans;

$X_1X_2f(X_1, X_2)$

$X_1$ ve $X_2$	1	2	3	4	5	6	
1	0.028	0.056	0.083	0.111	0.139	0.167	
2	0.056	0.111	0.167	0.222	0.278	0.333	
3	0.083	0.167	0.250	0.333	0.417	0.500	
4	0.111	0.222	0.333	0.444	0.556	0.667	
5	0.139	0.278	0.417	0.556	0.694	0.833	
6	0.167	0.333	0.500	0.667	0.833	1.000	
							12.250

$$\text{cov}(X_1, X_2) = E(X_1X_2) - E(X_1)E(X_2) = 12.25 - 3.5 * 3.5 = 0$$

## VARYANS-KOVARYANS MATRİSİ (VARIANCE-COVARIANCE MATRIX)

$$\Sigma = \begin{pmatrix} \mathit{Var}(X_1) & \mathit{cov}(X_1, X_2) & \mathit{cov}(X_1, X_3) \\ \mathit{cov}(X_1, X_2) & \mathit{Var}(X_2) & \mathit{cov}(X_2, X_3) \\ \mathit{cov}(X_1, X_3) & \mathit{cov}(X_2, X_3) & \mathit{Var}(X_3) \end{pmatrix}$$

$$\mathit{cov}(X_i, X_i) = \mathit{Var}(X_i)$$

Örnek 6 için;  $\Sigma = \begin{pmatrix} 2.917 & 0 \\ 0 & 2.917 \end{pmatrix}$

## KORELASYON (CORRELATION)

Korelasyon katsayısı, sadece bir ilişkinin yönünü belirlemek için değil, aynı zamanda iki rastgele değişken arasında var olabilecek ilişkinin büyüklüğünün gücünü belirlemek için de kullanılır.

$$\rho = \frac{\text{cov}(X_1, X_2)}{\sigma_{X_1} \sigma_{X_2}}$$

$$-1 \leq \rho \leq +1$$

## KORELASYON ve KOVARYANS

Kovaryans, iki veya daha fazla rastgele deęişken kümesi arasındaki korelasyonun gücünün bir ölçümüdür. Korelasyon, bir kovaryansın ölçeklendirilmiş hali gibidir.

Kovaryans, -1 ile 1 arasında olmakla sınırlı deęildir. Ancak işaret her zaman aynı olacaktır ve sıfır kovaryans ile sıfır korelasyon tam olarak aynı anlama gelir.

Kovaryans deęişkenlerin orijinal birimlerinde olduęu için, daha büyük sayılara ve daha geniş dağılımlara sahip ölçeklerdeki deęişkenler zorunlu olarak daha büyük kovaryans deęerlerine sahip olacaktır.

## **ORTALAMA (MEAN)**

Tüm veri noktalarının toplamının toplam veri noktasına bölümü ile edilen değerdir.

$$\bar{X} = \frac{\sum X}{n}$$

## **MOD (MODE)**

Veri setindeki en sık gözlemlenen değerdir.

## **MEDYAN (MEDIAN)**

Sıralı bir veri setindeki orta değeri göstermektedir.

## ÖRNEKLEM İSTATİSTİKLERİ

Örneklem varyansı:

$$S_x^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n-1}$$

Örneklem kovaryansı:

$$cov(X_1, X_2) = \frac{\sum (X_1 - \bar{X}_1)(X_2 - \bar{X}_2)}{n-1}$$

Örneklem korelasyon katsayısı:

$$r = \frac{cov(X_1, X_2)}{S_{x_1} S_{x_2}}$$

# KESİKLİ TERCİH MODELLERİ

Discrete Choice Models



TEŞEKKÜRLER  
HAFTAYA GÖRÜŞMEK ÜZERE 😊

---

*Dr. Kadir Berkhan AKALIN*

# KAYNAK GÖSTERME

**Bu sunuma ařađıdaki gibi atıf yapabilirsiniz:**

*Akalın, K.B. (2023). Kesikli Tercih Modelleri Ders Notu. Eskiřehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü*

**You can cite this presentation as follows:**

*Akalın, K.B. (2023). Discrete Choice Models Lecture Notes. Eskişehir Osmangazi University Graduate School of Natural and Applied Sciences.*



# KAYNAKLAR

- Akalın, K.B. (2021). *Yolculuk Üretim ve Çekim Modellerinin Rastgele Pişmanlık Minimizasyonu ve Rastgele Fayda Maksimizasyonu Yöntemleri ile Geliştirilmesi*. Doktora Tezi. Eskişehir Osmangazi Üniversitesi.
- Ben-Akiva, M., Bierlaire, M. (1999). *Discrete choice methods and their applications to short term travel decisions*. Handbook of transportation science.
- Ben-Akiva, M., Lerman, S. (1985). *Discrete Choice Analysis*, The MIT Press.
- De Dios Ortúzar, J., Willumsen, L.G. (2011). *Modelling Transport*. John Wiley & Sons.
- Frumin, M., Ben-Akiva M. (2008). *Transportation Systems Analysis: Demand And Economics*. MIT Open Courseware.
- Tezcan, H.O. (2021). *Discrete Choice Modelling in Transportation Lecture Notes*. İstanbul Technical University.
- Tezcan, H.O. (2021). *Transportation Models Lecture Notes*. İstanbul Technical University.
- Train, K. (2002). *Discrete Choice Methods with Simulation*, Cambridge University Press.
- [https://tr.wikipedia.org/wiki/Olas%C4%B1l%C4%B1k\\_da%C4%9F%C4%B1l%C4%B1m%C4%B1](https://tr.wikipedia.org/wiki/Olas%C4%B1l%C4%B1k_da%C4%9F%C4%B1l%C4%B1m%C4%B1)
- <https://www.wasyresearch.com/continuous-and-discrete-statistical-distributions-probability-density-mass-function-cumulative-distribution-function-and-the-central-limit-theorem/>
- [https://acikders.ankara.edu.tr/pluginfile.php/793/mod\\_resource/content/2/Olas%C4%B1l%C4%B1k%20ve%20Olas%C4%B1l%C4%B1k%20Da%C4%9F%C4%B1l%C4%B1mlar%C4%B1.pdf](https://acikders.ankara.edu.tr/pluginfile.php/793/mod_resource/content/2/Olas%C4%B1l%C4%B1k%20ve%20Olas%C4%B1l%C4%B1k%20Da%C4%9F%C4%B1l%C4%B1mlar%C4%B1.pdf)
- <https://towardsdatascience.com/probability-mass-and-density-functions-eab86a81d021>
- <https://towardsdatascience.com/bias-variance-and-how-they-are-related-to-underfitting-overfitting-4809aed98b79>
- <https://medium.com/datarunner/bias-ve-varyans-dengesi-%C3%BCzerinden-overfitting-ve-underfitting-durumlar%C4%B1n%C4%B1n-anla%C5%9F%C4%B1lmas%C4%B1-ca26cea65bb4>