

TANIMLAYICI İSTATİSTİKLER DEĞİŞİM VEYA DAĞILIŞ ÖLÇÜLERİ

DEĞİŞKENLİK NEDİR?

● Bir ana kütle (popülasyonu) tanıtmak için, veya başka ana kütlelerle karşılaştırabilmek için merkezi ölçülerin yanında dağılımın genişliğini, değişkenliğin büyüklüğünü gösteren bir başka tipik değerin verilmesi gerekmektedir.


Bu tipik değer değişkenlik ölçüsüdür.

Örnek:

- ▶ $X_i: \{ 49, 49, 49, 50, 51, 52 \} ; \bar{X} = AO(X) = 50$
- ▶ $Y_i: \{ 35, 41, 50, 55, 58, 61 \} ; \bar{Y} = AO(Y) = 50$
- ▶ $Z_i: \{ 15, 21, 33, 49, 90, 92 \} ; \bar{Z} = AO(Z) = 50$

- Bu üç deęişkenin ortalaması aynı olduęu halde X, Y ve Z deęişkenlerinin aldığı deęerlerin en küçük ve en büyük deęerlerine bakıldığında birbirlerinden çok farklıdır.
- Bir popülasyonun gözlem deęerlerinde görülen bu deęişimin bir istatistikle ifade edilmesi gerekir.

Dağılıř veya deęişimleri ifade için kullanılan bu ölçümlere dağılıř veya deęişim ölçüleri denir.



X deęerleri 50 nin etrafında çok yakın kümелendięi halde, Y deęerleri biraz daha daęınık, Z deęerleri 50 den çok uzakta yer almakta, yani daha büyük deęişim göstermektedir.

Dolayısıyla deęişkenin ortalama deęeri 50 dir demek deęişkeni tanımlamak için yeterli olmuyor. Bunun yanında başka ölçütlerde vermek gerekmektedir. Bu ölçüt deęişkenlik ölçütü olabilir.

BAŞLICA DEĞİŞİM ÖLÇÜTLERİ

- Değişim Aralığı veya Genişliği (Range)
- Çeyrek Ayrılış (IQR)
- Yarı Çeyrek Ayrılış (SIQR)
- Ortalama Mutlak Sapma
- Variyans
- Standart Sapma
- Standart hata
- Değişim (Varyasyon) katsayısı

DEĞİŞİM GENİŞLİĞİ(RANGE)

En basit dağılış ölçüsü Değişim Genişliğidir.

Değişim Genişliği=DG=R=

= (En Büyük Gözlem – En Küçük Gözlem)

$$\blacktriangleright DG(X) = [X_{(enbuy)} - X_{(enkuc)}] = 52 - 49 = 3$$


$$\blacktriangleright DG(Y) = [Y_{(enbuy)} - Y_{(enkuc)}] = 61 - 35 = 26$$

$$\blacktriangleright DG(Z) = [Z_{(enbuy)} - Z_{(enkuc)}] = 92 - 15 = 77$$


Olur.

Bu tip değişkenliğe sahip dağılışların grafiklerine bakıldığında aşağıdaki şekilde bir görünüş söz konusudur.


X



Y



Z



Değişim genişliği veya buna dayanan ölçütler (IQR, SIQR) aslında çok kullanılan ölçülerdir. örneğin şeker hastasının en küçük ve en yüksek değerleri nedir, ateşli bir hastanın en düşük ve en yüksek ateş derecesi nedir, kişiler bu tip değerlerle sürekli ilgilenilir. Özellikle sıralı ölçekteki verilerin tanıtıcı istatistikleri verilirken bunlardan yararlanır.

- Ancak değişim genişliğinde sadece iki aşırı uç değer kullanıldığı için istikrarlı bir ölçü değildir, bilgi kaybı çoktur, çünkü verinin büyük bir kısmı kullanılmamaktadır.

- Diğer bir sakıncası değişim genişliği örnek büyüklüğüne çok bağlıdır. Örnek büyüdükçe aşırı değerleri kapsama olasılığı artar.

ÇEYREK AYRILIŞ(IQR), YARI ÇEYREK AYRILIŞ (SIQR)

- Üçüncü ve birinci çeyrekliklerin farkı çeyrek ayrılıştır. $IQR = (Q_3 - Q_1)$
- Yarı Çeyrek Ayrılış ($SIQR = (Q_3 - Q_1) / 2$)
- Bu istatistikler genelde sıralama ölçeği ile ölçülen özelliklerin tanımlayıcı istatistiklerinde değişkenliği tanımlarken kullanılır.

Sıralama ölçeğine sahip değişkenlerde merkezi bölgeyi tanımlarken medyan kullanılmasının doğru olacağı daha önce belirtilmişti. Değişkenlik ölçüsü olarak da R, IQR veya SIQR kullanılabilir.

ORTALAMA MUTLAK SAPMA

- Ortalama Mutlak Sapma veya Ayrılış

$$OA = \frac{1}{n} \sum_{i=1}^n |X_i - \bar{X}|$$

- Ortalama mutlak sapma tüm veriyi kullandığı için değişim genişliğinden daha güçlü bir istatistiktir.

- Ancak bunun sakıncası da, üzerinde cebirsel işlemlerin yapılmasının zorluğudur. Yani iki grubun (n) leri ve ortalama mutlak sapmaları verilse, bunlar birleştirildiğinde birleşik örneğin ortalama mutlak sapmasını hesaplayın dendiğinde bu bulunamaz.

Bunların yerine verinin tamamını kullanan, üzerinde cebirsel işlemlerin daha kolay yapılabildiği bir değişkenlik ölçüsünün kullanılması daha faydalı olacaktır.

Bu ölçü variyans ve buna dayanan ölçülerdir.

VARIYANS

Variyans deęişkenlerin aldığı deęerlerin kendi ortalamasından ayrılışlarının karelerinin toplamının (n-1) bölünmesi ile elde edilir. Eğer popülasyon ortalaması (μ) biliniyorsa n bölünerek te elde edilebilir. Ancak genelde μ bilinmez bu nedenle de yansız tahmin için (n-1) e bölünür.

X_i : $\{ X_1, X_2, \dots, X_n \}$ deęerler kümesinin variyansı iki farklı şekilde hesaplanabilir:

$$\text{Variyans} = S^2 = \underbrace{\frac{\sum_{i=1}^n (x_i - \bar{X})^2}{n-1}}_{\text{ilk hesaplama şekli}} = \frac{1}{n-1} \underbrace{\left(\sum_{i=1}^n x_i^2 - \frac{(\sum_{i=1}^n x_i)^2}{n} \right)}_{\text{ikinci hesaplama şekli}}$$

BIYOİSTATİSTİK VE TIP BİLİŞİMİ

A.D.

Eşitliğin sağ tarafındaki sonraki formül ile bir önceki tamamen aynıdır, biri diğerinin açılmış halidir.

Örnek:

$X_i: \{49, 49, 49, 50, 51, 52\}$

değişkeninin varyansı nedir?

İLK FORMÜLÜN KULLANILIŞI

X_i	$(X_i - \bar{X})$	$(X_i - \bar{X})^2$
49	-1,0	1,0
49	-1,0	1,0
49	-1,0	1,0
50	0,0	0,0
51	1,0	1,0
52	2,0	4,0

$$n = 6$$

$$\text{Toplam} = \sum X_i = 300 \quad \sum_{i=1}^6 (x_i - \bar{x})^2 = 8,0$$

$$\text{Ortalama} = \sum X_i / n = 50 \quad S^2 = 8/5 = 1,6$$

İKİNCİ FORMÜLÜN KULLANILIŞI

X_i	(X_i^2)
49	2401,0
49	2401,0
49	2401,0
50	2500,0
51	2601,0
52	2704,0

n= 6

Toplam= 300 15008,0

Variyans =

$$S^2 = \frac{1}{n-1} \left(\sum_{i=1}^n X_i^2 - \frac{(\sum_{i=1}^n X_i)^2}{n} \right)$$

Variyans =

$$S^2 = \frac{1}{6-1} \left(15008 - \frac{300^2}{6} \right) = \frac{8}{5} = 1,6$$

Her iki formülden de aynı sonuç elde edilmektedir.

$$S^2 = [(49-50)^2 + (49-50)^2 + (49-50)^2 + (50-50)^2 + (51-50)^2 + (52-50)^2] / (6-1) = (1+1+1+0+1+4) / 5 = 8/5 = 1.6$$

Veya ikinci formül kullanılırsa;

$$S^2 = [(49^2 + 49^2 + 49^2 + 50^2 + 51^2 + 52^2) - 300^2 / 6] / 5 = (15008 - 15000) / 5 = 8/5 = 1.6$$

X'in varyansı olduğunu ifade için $S_x^2 = 1.6$ yazılabilir. Sonuç aynıdır.

Aynı şekilde Y nin ve Z nin varyansları da hesaplanabilir.

$$S_y^2 = 103.2, S_z^2 = 1144 \text{ bulunur.}$$

FREKANS(SIKLIK) TABLOSUNDAN VARIYANS HESAPLANMASI

Daha önce merkezi ölçülerin hesaplanmasında verilen örnek kullanılırsa, “yüz yeni doğan çocuğun doğum ağırlıkları (kg) ile ilgili sıklık tablosundaki gruplandırılmış olan veri setine” ait varyans nasıl hesaplanacaktır ?

ÇOCUK DOĞUM AĞIRLIĞI SIKLIK TABLOSU

Sınıf sınırları	Sınıf Değeri (X_i)	Sıklık (frekans= f_i)
1.45 - 1.94	1.7	2
1.95 - 2,44	2,2	18
2,45 – 2,94	2,7	24
2,95 – 3,44	3,2	19
3,45 – 3,94	3,7	18
3,95 – 4,44	4,2	9
4,45 – 4,94	4,7	6
4,95 – 5,44	5,2	4
		100

SINIFLANDIRILMIŞ VERİLERDE VARIYANS HESABI

Sınıf sınırları	(X_i)	(f_i)	$f_i \cdot X_i$	$f_i \cdot (X_i)^2$
1.45 - 1.95	1.7	2	3,4	5,78
1.95 - 2,45	2,2	18	39,6	87,12
2,45 – 2,95	2,7	24	64,8	174,96
2,95 – 3,45	3,2	19	60,8	194,56
3,45 – 3,95	3,7	18	66,6	246,42
3,95 – 4,45	4,2	9	37,8	158,76
4,45 – 4,95	4,7	6	28,2	132,54
4,95 – 5,45	5,2	4	20,8	108,16
	Σ	100	322	1108,3

$$\text{Varyans} = \frac{1}{\sum_{i=1}^k f_i - 1} \left(\sum_{i=1}^k f_i \cdot X_i^2 - \frac{(\sum_{i=1}^k f_i X_i)^2}{\sum_{i=1}^k f_i} \right)$$

$$S^2 = \frac{1}{100 - 1} \left(1108.3 - \frac{322^2}{100} \right) = 0.722$$

Variyanstan hesaplanan diğer deęişkenlik ölçütleri **Standart Sapma**, **Standart Hata** ve **Varyasyon(Deęişim) Katsayısı** çok sık kullanılan deęişkenlik istatistikleri olarak karşımıza çıkar.

Bunların nasıl hesaplandığı üzerinde duralım.

STANDART SAPMA

Standart sapma varyansın kare köküdür. Varyans birimsiz ifade edildiği halde standart sapma ölçülen özelliğin birimi ile ifade edilir. Ortalama etrafındaki saçılma fazla ise varyans büyük olacak, dolayısıyla standart sapma da büyük çıkacaktır. Varyans hesaplanırken ortalamadan ayrılışların kareleri üzerinden hesap yapıldığı için aşırı değerlerin varyans üzerindeki etkisi ortalamaya yakın değerlerden daha fazla olur.

- Veri seti içinde aşırı değer fazla ise bunların varyansı etkilemesi olağan karşılanabilir, ancak birkaç aşırı değer için varyansı büyütmesi olağan karşılanmaz.

- Aşırı değerlerin az olduğu durumlarda ortalama yerine ortanca, standart sapma yerine de çeyrek ayrılışın kullanılması uygun olur.

Ancak çeyrek sapma hesaplanırken tüm veriler yerine sadece dörtte birlik sınırlar (Q1 ve Q3) kullanıldığından standart sapmadan daha zayıf bir dağılım ölçüsüdür. Ortanca kullanmanın gerekli olduğu hallerde çeyrek sapmada değişim ölçüsü olarak kullanılır.

ÖRNEK:

$X_i: \{49, 49, 49, 50, 51, 52\}$ veri seti için varyans daha önce hesaplandı. Bunun standart sapması (S) nasıl bulunur? Varyansın karekökü standart sapmadır.

$$S = \sqrt{\text{Varyans}} = \sqrt{S^2}$$

$$\text{Standart sapma} = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{X})^2}{n-1}} = \sqrt{\frac{1}{n-1} \left(\sum_{i=1}^n x_i^2 - \frac{(\sum_{i=1}^n x_i)^2}{n} \right)}$$

Standart sapma **S** veya **S_x** şeklinde değişken ismi ile birlikte yazılabilir.

$$S = \sqrt{\text{Varyans}} = \sqrt{S^2} = \sqrt{1.6} = \mathbf{1.26},$$

Aynı şekilde Y ve Z değişkenlerinin standart sapmaları hesaplanırsa:


$$S_y = \sqrt{103.2} = \mathbf{10.16},$$
$$S_z = \sqrt{1144} = \mathbf{33.82} \text{ bulunur.}$$

$$\bar{X} \pm S_x \quad 50 \pm 1.26 \text{ ifadesi}$$


kullanılabilir

Standart sapma gözlemlerin değişkenliği ile ilgili bir göstergedir.


Normal dağılıfta gözlemlerin %68.27 si ortalamamanın ± 1 standart sapma, gözlemlerin %95.45 i ± 2 standart sapma, %99.7 si ± 3 standart sapma sağında ve solunda yer alır.



ÇARPIK DAĞILIŞLAR



Pozitif(sağa) Çarpık



Negatif(sola) çarpık

Çarpık dağılışlarda bu tip bir ilişkiden bahsetmek söz konusu değildir. Bu nedenle çarpık dağılışlarda güven sınırından bahsetmek anlamsız olur.

STANDART HATA

$$\text{Standart Hata} = \sqrt{\frac{\text{Varyans}}{n}} \Rightarrow S_{\bar{x}} = \sqrt{\frac{S^2}{n}}$$

$$S_{\bar{x}} = \sqrt{\frac{S^2}{n}} = \sqrt{\frac{1.6}{6}}$$

$$= 0.52$$

Standart sapma ve standart hata Normal dağılım gösteren özellikler için oldukça kullanışlıdır.

GÜVEN SINIRI

Ortalamanın dağılışı:

$$\bar{X} \sim N\left(\mu, \frac{\sigma^2}{n}\right) \text{ ise}$$

$$Z = \frac{\bar{X} - \mu}{\sigma / \sqrt{n}} \sim N(0,1)$$

Şeklinde
standardize edilir.

Dağılış simetrik ise ana kütle ortalamasına (μ) ait güven sınırı hesaplanabilir.


$$P\left[\bar{X} - Z_{(\alpha/2)} \cdot S_{\bar{X}} \leq \mu \leq \bar{X} + Z_{(\alpha/2)} \cdot S_{\bar{X}}\right] = \%(1 - \alpha)$$

Burada Z standart normal dağılışın (alfa düzeyindeki) tablo değeridir.

GÜVEN SINIRI

$$P \left[-z_{\alpha/2} \leq Z = \frac{\bar{X} - \mu}{\sigma / \sqrt{n}} \leq z_{\alpha/2} \right] = 1 - \alpha$$

$$\bar{x} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{x} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}$$



X DEĞİŞKENİ İÇİN %95 LİK GÜVEN SINIRLARI

$$\bar{X} = 50$$

$$S_{\bar{X}} = 0,52$$

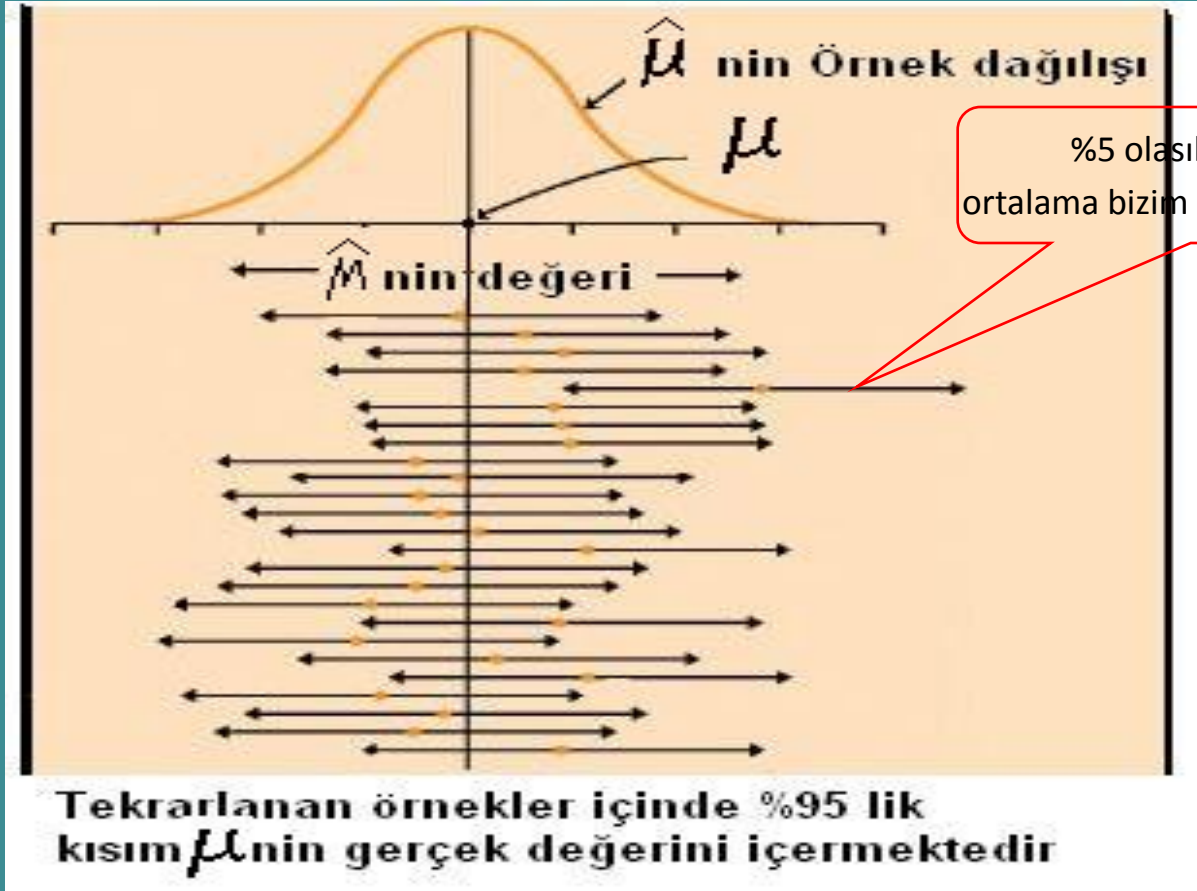
$$Z_{(0.025)} = 1,96$$

$$L = \bar{X} - Z_{(\alpha/2)} \cdot S_{\bar{X}} = 50 - 1,96 \times 0,52 = 48,98$$

$$U = \bar{X} + Z_{(\alpha/2)} \cdot S_{\bar{X}} = 50 + 1,96 \times 0,52 = 51,02$$


Alt güven sınırı=48,98, üst güven sınırı=51,02
Olur.

GÜVEN SINIRININ ANLAMI



Bulduğumuz güven sınırının gerçek ortalamayı (μ) kapsadığını %95 güvenle söyleyebiliriz.

Normal Dağılım Olasılık Yoğunluk Fonksiyonu



X, Y ve Z deęişkenlerine ait İstatistikler

	N	DG	Ortalama	s² veya S_x² Varyans	S_x Standart Sapma	S_{\bar{x}} Standart Hata
X	6	3	50	1,6	1,26	0,516
Y	6	26	50	103,2	10,16	4,147
Z	6	77	50	1144,0	33,82	13,808

Bir serinin ortalaması verilirken standart hatası ile birlikte verilir, şöyle ki:

Aritmetik Ortalama \pm Standart Hata

$$\bar{X} \pm S_{\bar{X}}$$

X_i serisi için bunun ifadesi: 50 ± 0.52 .

Y_i serisi için 50 ± 4.15 ,

Z_i serisi için 50 ± 13.8

şeklindedir olur.

Böylece ortalamaya ait değişkenlik te yanında ifade edilmiş olur.

Standart hata ortalamanın güvenilirliği ile ilgili bir ölçüdür. Standart hata ne kadar küçükse ortalama o kadar güvenilirdir.

DEĞİŞİM VEYA VARYASYON KATSAYISI(VK)

Bir serinin standart sapması kendi aritmetik ortalamasının yüzdesi olarak ifade edilirse değişim katsayısı bulunmuş olur.

- V.K= Standart Sapma*100/ Ortalama

$$\text{Varyasyon Katsayısı} = \frac{S}{\bar{X}} * 100$$

- Xi serisi için: V.K= 1.26 *100 /50=%2.52
- Yi için; V.K=10.16*100/50= %20.32
- Zi için; V.K= 33.82*100/50=%67.64 olur.

VARYASYON KATSAYISININ (VK) KULLANIMI

● A ve B gibi iki farklı popülasyondaki deęişkenlięi karşılaştırmak istersek doğrudan standart sapma veya standart hatalarına bakmak yanıltıcı olabilir.

● Ana kütlelerin ortalamaları büyüklük olarak birbirinden çok farklı ise (fillerin ağırlığını daha deęişkendir, farelerin ağırlığını ?) standart sapma deęerlerini ölçü biriminden bağımsız hale getirmek gerekir. Bunun için Deęişim(varyasyon) kullanılır.

Örneğin fillerin ağırlığını daha deęişkendir, farelerin ağırlığını sorusunun cevabı için V.K. kullanılır.

- İki özellik farklı birimlerle ölçülüyorsa, örneğin üzerlerinde deneme yapılan farelerin kan şekeri daha değişkendir yoksa vücut ağırlıkları sorusu ile karşılaşılsa bunun için varyasyon katsayılarına bakmak gerekir.
- Ortalamanın sifıra yakın olduğu durumlarda varyasyon katsayısının güvenirliliği azalır. Bu gibi durumlarda dikkatli olmak gerekir.
- %20 nin üzerinde varyasyon katsayısı fazla değişkenlik olduğunun göstergesi olarak görülür.

Örnek:Aynı şahıs üzerinde iki farklı yöntemle (X:autoanalyser, Y:Microenzymatic) ölçülen kolesterol miktarları aşağıda verilmiştir.

● X: { 177,193,195,209, 226} %mg/ml

● Y: {192,197,200,202,209}

Her ikisinin aritmetik ortalaması eşittir.

$$AO(X)= 1000/5=200, AO(Y)=1000/5=200$$

$$V(X)=(201360-200000)/4=340, S=18.44$$

$$V(Y)=(200158-200000)/4=39.5, S=6.28$$

$$VK(X)=18.44*100/200=%9.22$$

$$VK(Y)=6.28*100/200=%3.14 \text{ olur.}$$

VARIYANSLA İLGİLİ BAZI ÖNEMLİ HESAPLAMALAR

Veri setini sabit bir sayı ile toplama ve çıkarmanın ortalama ve varyans üzerine etkisi:

C sabit bir sayı ise $Y_i = X_i + C$ şeklinde verilerin tamamına **C** sayısı eklense yeni elde edilen sayının ortalama ve varyansı değişir mi?

● $E(X_i) = \mu$, $E(Y_i) = E(C + X_i) = E(C) + E(X_i) = C + \mu$
ortalama C kadar artar.

● $V(X_i) = \sigma^2$ ise, $V(Y_i) = V(C + X_i) = V(C) + V(X_i) = 0 + \sigma^2$
varyans aynı kalır.

ÖRNEK:

- $X_i: \{4, 5, 6, 9\}$ ise

Ortalama(X)= $24/4=6$, varyans(X)=4.67

Tüm değerlere $c=3$ sabiti eklense

- $Y_i = \{7, 8, 9, 12\}$ elde edilir.

Y_i nin ortalaması ve varyansı ne olur?

Ortalama(Y)= $36/4=9$, varyans(Y)=4.67

Olur.

C sabit bir sayı ise verilerin tamamı **C** sayısı ile çarpılsa yeni elde edilen sayının ortalama ve varyansı değişir mi?

- $Y_i = C \cdot X_i$ olursa,

- $E(X_i) = \mu$, $E(Y_i) = E(C \cdot X_i) = C \cdot E(X_i) = C\mu$,
ortalama C kat artar.

- $V(X_i) = \sigma^2$ ise, $V(Y_i) = V(C \cdot X_i) = C^2 \cdot V(X_i) = C^2 \cdot \sigma^2$,
varyans sabit sayının karesi ile çarpımı kadar büyür.

- $X_i: \{ 4, 5, 6, 9 \}$ ise
- $\text{Ortalama}(X) = 24/4 = 6$, $\text{variyans}(X) = 4.67$

- Tüm değerlere $c=3$ sabiti ile çarpılsa
- $Y_i = \{12, 15, 18, 27\}$ elde edilir.
- Y_i nin ortalaması ve varyansı ne olur?
- $\text{Ortalama}(Y) = 72/4 = 18$, $\text{variyans}(Y) = 42,0$