

DÖNÜŞÜMLER (TRANSFORMATIONS)

İstatistiksel yöntemlerin bir çoğu normallik varsayımına dayanır.

- Deney tasarımı
- Regresyon
- Zaman serileri

alanlarındaki yöntemler buna örnek olarak verilebilir. Bu nedenle analize başlamadan önce veri setinin dağılımının normal olup olmadığının test edilmesi gerekir. Eğer veri setinin dağılımı normal değilse veri seti aşağıda gösterilen alternatif yaklaşımlardan bir tanesi kullanılarak analiz edilmelidir.

Bu alternatif yaklaşımlar

- Parametrik Olmayan Teknikler
- Dayanıklı (Robust) Teknikler
- Dönüşümler

olarak gruplandırılabilir.

Bu bölümde dönüşümler konusu detaylı olarak incelenecektir. Veri setinin dağılımı normal olmadığında uygun dönüşüm yapılarak veri setinin dağılımı normal hale getirilir ve normal dağılım varsayımına dayanan testler kullanılarak analize devam edilir.

Not: Burada önemli olan hangi dönüşümün yapılacağına karar vermektir.

Üssel dönüşümler (Power transformations)

Üssel dönüşümler uygulamada yaygın olarak kullanılır. Sadece pozitif değerler alan gözlemler için kullanılabilir, ancak bu problem negatif değerler alabilen gözlemlere belli bir sabit ekleyerek söz konusu negatif değerleri pozitif hale getirerek ortadan kaldırılabilir.

x bir gözlem olmak üzere, üssel dönüşüm λ parametresi ile ilişkilendirilir. λ değeri belirli bir dönüşümü temsil eder.

Örnek: x^λ dönüşümü kullanıldığında

$\lambda = -1$ ise $x^{-1} = \frac{1}{x}$ olduğundan tüm gözlemlerin tersi alınarak dönüşüm yapılır.

$\lambda = 0$ ise $x^\lambda = \ln x$ olarak tanımlanmaktadır. Bu durumda tüm gözlemlerin doğal logaritması (ln) alınarak dönüşüm yapılır.

Mümkün dönüşümler

$$x^{-1} = \frac{1}{x}, x^0 = \ln x, x^{1/4} = \sqrt[4]{x}, x^{1/2} = \sqrt{x}, x^2, x^3$$

şeklinde gösterilebilir.

Bu dönüşümlerden,

$x^{-1}, x^0, x^{1/4}, x^{1/2}$ büyük değerli gözlemleri aşağıya çekerken

x^2, x^3 gibi dönüşümler büyük değerli gözlemleri daha da artırır.

Box-Cox Dönüşümü

$x > 0$ için

$$x^{(\lambda)} = \begin{cases} \frac{x^\lambda - 1}{\lambda} & \lambda \neq 0 \\ \ln x & \lambda = 0 \end{cases}$$

şeklinde tanımlanır.

Uygun λ değeri, aşağıdaki $l(\lambda)$ fonksiyonunu λ 'ya göre maksimize eden değer bulunmasıyla belirlenir. Burada,

$$l(\lambda) = -\frac{n}{2} \ln \left[\frac{1}{n} \sum_{j=1}^n (x_j^{(\lambda)} - \bar{x}^{(\lambda)})^2 \right] + (\lambda - 1) \sum_{j=1}^n \ln x_j$$

dır ve

$$\bar{x}^{(\lambda)} = \frac{1}{n} \sum_{j=1}^n x_j^{(\lambda)} = \frac{1}{n} \sum_{j=1}^n \left(\frac{x_j^{(\lambda)} - 1}{\lambda} \right)$$


şeklinde tanımlanır.

Verileri dönüştürmek için kullanılacak uygun λ değeri belirlendikten sonra, dönüştürülen verilerin Q-Q grafiği çizilerek dağılımın normale uyup uymadığı kontrol edilir.

Örnek: Aşağıdaki veri setine Box-Cox dönüşümünü uygulayınız.

<i>i</i>	<i>x</i>	<i>i</i>	<i>x</i>
1	0.0001	26	0.6824
2	0.0012	27	0.6960
3	0.0439	28	0.7735
4	0.0612	29	0.7846
5	0.1104	30	0.8454
6	0.2040	31	0.8625
7	0.2298	32	0.9307
8	0.2315	33	1.0497
9	0.2420	34	1.0865
10	0.2438	35	1.1022
11	0.2534	36	1.2232
12	0.2959	37	1.2679
13	0.3286	38	1.3481
14	0.3357	39	1.3637
15	0.3692	40	1.3895
16	0.3885	41	1.4969
17	0.3935	42	1.5587
18	0.5170	43	1.7953
19	0.5356	44	1.9355
20	0.5560	45	2.1845
21	0.6161	46	2.2269
22	0.6167	47	2.3061
23	0.6452	48	2.6206
24	0.6543	49	3.0595
25	0.6789	50	4.0151

Öncelikle verilerin Q-Q grafiği aşağıdaki şekilde gösterildiği gibi çizilmiş ve gözlemlerin düz bir doğru etrafında yayılım göstermediği görülmüştür. Sonuç olarak orijinal verinin dağılımının normal olmadığı gösterilmiştir.



Not: Q-Q grafiđi verilerin normal dađılıma sahip olması durumunda döz bir dođru řeklinde olur. Eđer normal dađılımdan sapmalar varsa Q-Q grafiđindeki bazı gözlemler dođrudan sapmalar gösterir.

řimdi uygun λ deđerini belirlemek için rastgele olarak sečilmiř bir aralıktaki deđerler λ deđerlerine karřılık gelen $l(\lambda)$ deđerlerini elde edelim. Bu örnekte $\lambda \in [-1.0, 1.5]$ olarak alınmıřtır. Bu aralıđın $l(\lambda)$ fonksiyonunun maksimum olduđu noktayı kapsamalıdır. Sonuřlar ařađıdaki tabloda gösterildiđi gibi elde edilmiřtir.


λ	$l(\lambda)$	λ	$l(\lambda)$
-1.0	-291.4442	0.3	26.0313
-0.9	-254.2973	0.4	26.6314
-0.8	-217.8169	0.5	25.6828
-0.7	-182.1864	0.6	23.6352
-0.6	-147.6599	0.7	20.7669
-0.5	-114.5884	0.8	17.2532
-0.4	-83.4544	0.9	13.2091
-0.3	-54.9101	1.0	8.7139
-0.2	-29.7975	1.1	3.8252
-0.1	-9.0628	1.2	-1.4131
0.0	6.5692	1.3	-6.9660
0.1	17.0618	1.4	-12.8048
0.2	23.1754	1.5	-18.9050

Yukarıdaki tablodan $l(\lambda)$ fonksiyonunu maksimum yapan λ değerinin 0.4 olduğu görülmektedir. Orijinal verilere (x_j) , $\lambda = 0.4$ alınarak Box-Cox dönüşümü uygulanırsa

$$x_j^{(0.4)} = \frac{x_j^{0.4} - 1}{0.4}, \quad j = 1, 2, \dots, 50$$

olarak ifade edilen dönüştürülmüş veriler elde edilir.

Dönüştürülmüş verilerin Q-Q grafiği aşağıdaki gibidir.



Dönüştürülmüş verilerin normal dağılıma sahip olduğu görülür. Çünkü Q-Q grafiğinden de görüleceği gibi veriler düzgün bir doğru etrafında yayılım göstermektedir.

Not: λ için aralık belirlenirken $l(\lambda)$ fonksiyonunun bu aralıkta önce artan sonra azalan olması gerekir. Aksi takdirde kullanılan aralık maksimum noktayı kapsamaz.