




# VERİ MADENCİLİĞİ

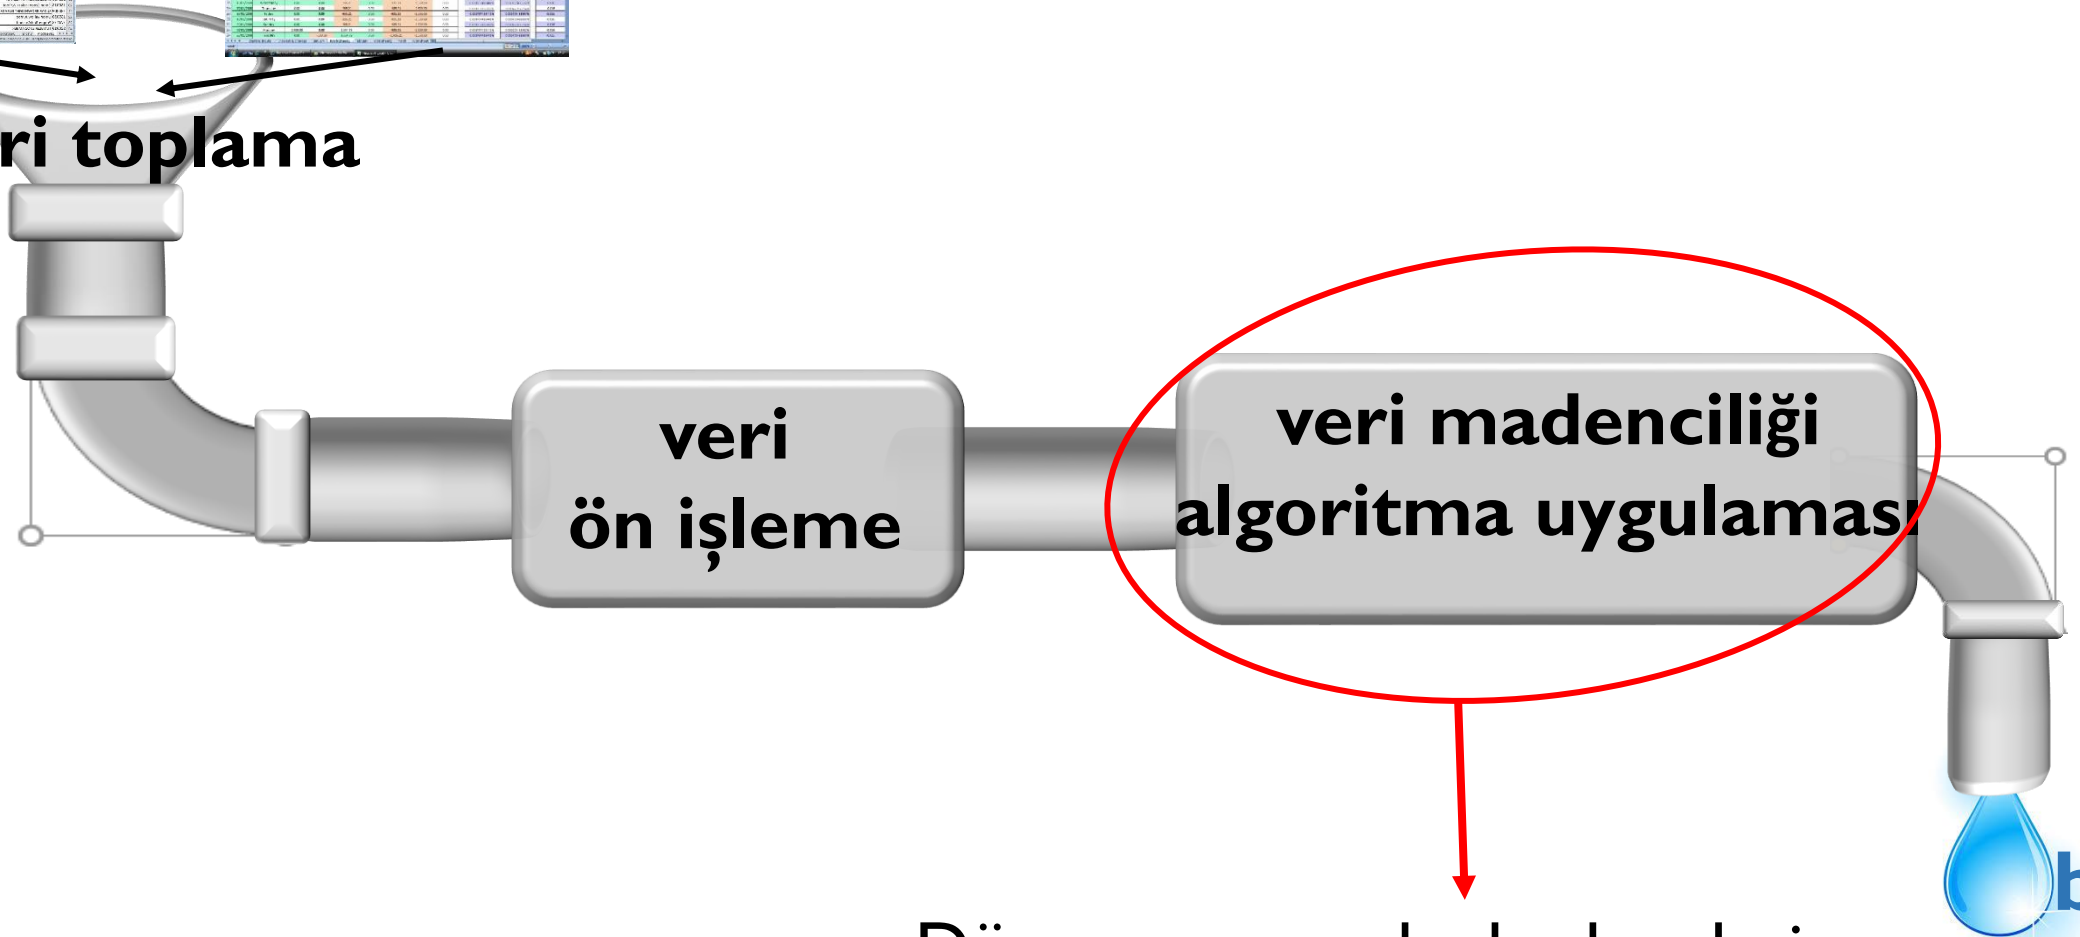
Fırat İsmailođlu, PhD

Naive Bayes ve Lojistik Regresyon





**veri toplama**



**veri  
ön işleme**

**veri madenciliği  
algoritma uygulaması**

**bilgi**

**Dönem sonuna kadar burdayız.**

## Bayes Teoremi

$X$  ve  $Y$  iki rastgele deęisken (random variable) olsun. Bu durumda  $X$  ve  $Y$ 'nin bileşik olasılığı (joint probability)  $P(X, Y)$  iki şekilde hesaplanabilir:

$$P(X, Y) = P(Y|X) \cdot P(X)$$

$$P(X, Y) = P(X|Y) \cdot P(Y)$$

Bu iki denklemi birbirine eşitlersek:

$$P(Y|X) \cdot P(X) = P(X|Y) \cdot P(Y)$$

olur.  $P(Y|X)$  yalnız bırakılırsa Bayes teoremi elde edilir :

$$P(Y|X) = \frac{P(X|Y) \cdot P(Y)}{P(X)}$$

$P(Y = y|X = x)$ :  $X$  deęişkeni  $x$  iken  $Y$  deęiskeninin  $y$  olma olasılığı.

Ayrıca bu ifadeye 'şartlı olasılık' da denir.  $X = x$  olması şartıyla  $Y$ 'nin  $y$  olma olasılığı..



**ör.** Bir klinikte yapılan kanser testi gerçekte kanser olan hastaların %98'inde pozitif olarak sonuç veriyor. Bu test, gerçekte kanser olmayan hastaların %97'sinde negatif olarak sonuç veriyor. Ayrıca toplumdaki kişilerin 0.008'nin kanser olduğu biliniyor.

Buna göre kanser testi pozitif çıkmış bir kişinin gerçekte kanser olma olasılığı nedir?

**Çözüm:**

Verilenler:

$P(kanser) = 0.008$  //kişi hakkında hiçbir bilgi yokken kişinin kanser olma olasılığı

$P(\neg kanser) = 0.992$

$P(test\ pozitif|kanser) = 0.98$  //kişi kanser iken testinin pozitif olma olasılığı

$P(test\ negatif|kanser) = 0.02$

$P(test\ negatif|\neg kanser) = 0.97$  //kişi kanser değilken testinin negatif çıkma olasılığı

$P(test\ pozitif|\neg kanser) = 0.03$

İstenen:

$P(kanser|test\ pozitif) = ?$



Bayes teoremi ile:

$$P(kanser|test\ pozitif) = \frac{P(test\ pozitif|kanser) \times P(kanser)}{P(test\ pozitif)}$$

Burada bilmediğimiz şey  $P(test\ pozitif)$ . Yani kişinin kanser olup olmadığına bağlı olmaksızın testinin pozitif çıkma olasılığı.

Bir kişi ya kanserdir yada kanser değildir. O halde testin pozitif çıkması kanserli kişilerde ve kanser olmayan kişilerde görülür.

Bir kişinin kanser olması ve testinin pozitif çıkması:  $P(test\ pozitif, kanser)$ .

Bir kişinin kanser olmaması ve testinin pozitif çıkması:  $P(test\ pozitif, \neg kanser)$ .

$$\begin{aligned} P(test\ pozitif) &= P(test\ pozitif, kanser) + P(test\ pozitif, \neg kanser) \\ &= P(test\ pozitif|kanser) \cdot P(kanser) + P(test\ pozitif|\neg kanser) \cdot P(\neg kanser) \\ &= 0.98 \times 0.008 + 0.03 \times 0.992 \\ &= 0.0376 \end{aligned}$$



$$P(kanser|test\ pozitif) = \frac{0.98 \times 0.008}{0.0376} = 0.2$$

$$\text{Su halde } P(\neg kanser|test\ pozitif) = 1 - 0.2 = 0.8$$

Testi pozitif çıkan kişinin kanser olmama olasılığı çok daha yüksektir. O halde bu test pek güvenilir değildir!

**ör.** İki futbol takımı düşünün: T1 ve T2. Varsayalım ki T1, T2 ile yaptığı maçların %65'ni yenmiş olsun. T1'in T2'yi yendiği maçların %70'i kendi sahasında gerçekleşmiş olsun. Öte yandan T2'nin T1'i yendiği maçların %75'i kendi sahasında gerçekleşmiş olsun. Eğer gelecek maç T1'in sahasında olacaksa bu maçı hangi takımın kazanması daha olasıdır?

**Çözüm:**

$$P(T1'in\ kazanmasi) = 0.65$$

$$P(T2'nin\ kazanmasi) = 0.35$$

$$P(T1'in\ sahasi|T1'in\ kazanmasi) = 0.7$$

$$P(T2'nin\ sahasi|T2'nin\ kazanmasi) = 0.75$$

$$P(T1'in\ sahasi|T2'nin\ kazanmasi) = 0.25$$



$P(T1'nin\ kazanmasi|T1'nin\ sahasi) \ Vs\ P(T2'nin\ kazanmasi|T1'nin\ sahasi)$

$$P(T1'nin\ kazanmasi|T1'nin\ sahasi) = \frac{P(T1'nin\ sahasi|T1'nin\ kazanmasi) \times P(T1'in\ kazanmasi)}{P(T1'in\ sahasi)}$$

$$P(T2'nin\ kazanmasi|T1'nin\ sahasi) = \frac{P(T1'nin\ sahasi|T2'nin\ kazanmasi) \times P(T2'in\ kazanmasi)}{P(T1'in\ sahasi)}$$

Yukaridaki her iki olasilik hesaplamasinda da paydalar aynidir. Amacimiz yalnızca bu olasiliklari sıralamak olduğundan paydayi hesaplamaya gerek yoktur.

(Yinede hesaplanmak istenirse:

$$P(T1'in\ sahasi) = P(T1'nin\ sahasi|T1'nin\ kazanmasi) \times P(T1'in\ kazanmasi) + P(T1'nin\ sahasi|T2'nin\ kazanmasi) \times P(T2'in\ kazanmasi) )$$



$$P(T1'nin kazanmasi|T1'nin sahasi) = \frac{0.7 \times 0.65}{P(T1'in sahasi)} = \frac{0.455}{P(T1'in sahasi)}$$

$$P(T2'nin kazanmasi|T1'nin sahasi) = \frac{0.25 \times 0.35}{P(T1'in sahasi)} = \frac{0.08}{P(T1'in sahasi)}$$

Ilk olasilikta pay daha büyük olduğundan T1'in sahasında oynanacak maçta T1'in kazanma olasılığı daha yüksektir.

$$P(T1'nin kazanmasi|T1'nin sahasi) > P(T2'nin kazanmasi|T1'nin sahasi)$$





Elimizde bir sonuç (gözlem) varken biz bu sonucun ortaya çıkmasını sağlayabilecek birçok nedenden en olası olanını bulmak isteriz. Yani olabilecek her neden için  $P(\text{neden}|\text{sonuç})$  olasılığını hesaplarız.

Örneğin gözlemimiz ‘öksürük’ olsun ve biz ‘grip’ten şüphelenelim. Bu durumda  $P(\text{grip}|\text{öksürük})$  olasılığını hesaplamamız gerekir.

Öte yandan genellikle  $P(\text{sonuç}|\text{neden})$ ’i hesaplamak daha kolaydır. Yani elimizdeki sonuca yol açabilecek nedenin bu sonuca yol açma olasılığını hesaplamak daha kolaydır.

Örnek olarak  $P(\text{öksürük}|\text{grip})$  olasılığı.

Bayes teoremi bize  $P(\text{neden}|\text{sonuç})$ ’tan  $P(\text{sonuç}|\text{neden})$ ’e gitmemizi sağlar:

$$P(\text{neden}|\text{sonuç}) = \frac{P(\text{sonuç}|\text{neden}) \times P(\text{neden})}{P(\text{sonuç})}$$



Öksürük şikayeti (bulgusu) olan hastada bu şikayete yol açabilecek nedenler grip ve zatürre olsun. Amacımız  $P(\text{grip} | \text{öksürük})$  ve  $P(\text{zatürre} | \text{öksürük})$  şartlı olasılıklarını karşılaştırmaktır. Bayes teoremi ile:

$$P(\text{grip} | \text{öksürük}) = \frac{P(\text{öksürük} | \text{grip}) \times P(\text{grip})}{P(\text{öksürük})}$$

$$P(\text{zatürre} | \text{öksürük}) = \frac{P(\text{öksürük} | \text{zatürre}) \times P(\text{zatürre})}{P(\text{öksürük})}$$

Her iki olasılık hesabında da payda aynıdır. O halde bu iki olasılığı karşılaştırırken yalnız payları göz önüne alabiliriz.

Genellersek  $P(\text{sonuç})$  tüm nedenler için aynı olduğundan,  $P(\text{neden} | \text{sonuç})$ ;  $P(\text{sonuç} | \text{neden}) \times P(\text{neden})$  ile orantılıdır:

$$P(\text{neden} | \text{sonuç}) \propto P(\text{sonuç} | \text{neden}) \times P(\text{neden})$$



## Şartlı Bağımsızlık (Conditional Independence)

Ahmet ve Mehmet iki kardeş olsun. Bu kardeşlerde belirli bir genetik hastalığın görülme olasılıklarına bakalım.

Bu genetik bir hastalık olduğundan Ahmet'in ve Mehmet'in hasta olma olasılıkları birbirinden ayrı düşünülemez; birbirinden bağımsız değildir. O halde

$$P(\text{Ahmet hasta}, \text{Mehmet hasta}) \neq P(\text{Ahmet hasta}) \times P(\text{Mehmet hasta}).$$

Fakat Mehmet'in evlatlık olduğu bilirse; Ahmet'in ve Mehmet'in bu genetik hastalığı taşıma olasılıkları birbirinden bağımsız olur. O halde

$$\begin{aligned} &P(\text{Ahmet hasta}, \text{Mehmet hasta} | \text{Mehmet evlatlık}) \\ &= P(\text{Ahmet hasta} | \text{Mehmet evlatlık}) \times P(\text{Mehmet hasta} | \text{Mehmet evlatlık}). \end{aligned}$$

Mehmet'in evlatlık olması şartıyla Ahmet'in ve Mehmet'in bu hastalığı taşıma olasılıkları birbirinden bağımsızdır.



## Şartlı Bağımsızlık (Conditional Independence)

Genel formül:

$X_1, X_2, \dots, X_n$  rastgele değişkenler olsun. Eğer

$$P(X_1, X_2, \dots, X_n|Z) = P(X_1|Z) \times P(X_2|Z) \times \dots \times P(X_n|Z)$$

oluyorsa  $Z$ 'nin varlığında;  $X_1, X_2, \dots, X_n$  rastgele değişkenlerinin gerçekleşme olasılıkları birbirinden bağımsızdır.

## Bayes Teoreminin Sınıflandırmada Kullanılması

Bir test örneği  $x = (x_1, x_2, \dots, x_n)$  şeklinde verilsin. Bu örneği  $y_1, \dots, y_k$  sınıflarından en olası olanına eşlemek istiyoruz.

Burada her  $y_i$  ( $i \in \{1, \dots, k\}$ ) sınıfı için  $P(y_i|x)$  olasılığını hesaplarız. Bu olasılık elimizde  $x$  varken bunun  $y_i$  sınıfına ait olma olasılığıdır.

Test örneğini en yüksek  $P(y_i|x)$  olasılığına sahip sınıfa eşleriz. Formal olarak:

$$\hat{y} = \underset{i \in \{1, \dots, k\}}{\operatorname{argmax}} P(y_i|x)$$



$P(y_i|x)$  olasılığını Bayes teoremi kullanarak aşağıdaki gibi hesaplayabiliriz:

$$P(y_i|x) = \frac{P(x|y_i) \times P(y_i)}{P(x)}$$

Amacımız  $P(y_i|x)$  olasılıklarını kıyaslayarak en yüksek olasılığa sahip sınıfı seçmektir.  $P(y_i|x)$  hesaplamasında bütün sınıflar için (her  $i \in \{1, \dots, k\}$  için) payda ( $P(x)$ ) aynı olduğundan sınıflandırma yaparken  $P(x)$ 'i hesaplamıyoruz.

Bu durumda  $P(y_i|x)$  hesaplamasında yalnızca  $P(x|y_i) \times P(y_i)$  çarpımını dikkate alacağız:

$$P(y_i|x) \propto P(x|y_i) \times P(y_i)$$

$P(y_i)$ : eğitim setinde  $y_i$  sınıfının görülme olasılığı. Örneğin eğitim setindeki örneklerin %20'sinin sınıfı grip olsun. Bu durumda  $P(grip) = 0.2$  olur.

$P(x|y_i)$  :  $y_i$  sınıfında  $x$  örneğinin görülme olasılığı.

Örneğin  $x = (bulantı, yüksek ateş, burun tıkanıklığı)$ ,  $y_i = grip$  olsun.

$P(x|y_i)$  : hasta grip iken bulantı, yüksek ateş ve burun tıkanıklığının görülme olasılığı.



Bulantı, yüksek ateş ve burun tıkanıklığının gripin varlığında gerçekleşme olasılıklarının birbirinden bağımsız olduğunu varsayalım. Yani bu belirtileri şartlı bağımsız varsayalım.

Bu durumda:

$$\begin{aligned} P(x|y_i) &= P(\text{bulantı, yüksek ateş, burun tıkanıklığı}|\text{grip}) \\ &= P(\text{bulantı}|\text{grip}) \times P(\text{yüksek ateş}|\text{grip}) \times P(\text{burun tıkanıklığı}|\text{grip}). \end{aligned}$$

Bu varsayımı formülize edersek:

$$\begin{aligned} P(x|y_i) &= P(x_1|y_i) \times P(x_2|y_i) \times \cdots \times P(x_n|y_i) \\ &= \prod_{j=1}^n P(x_j|y_i). \end{aligned}$$



Amacımız  $P(y_i|x)$  olasılıklarını karşılaştırmaktır. Gördük ki bu olasılık  $P(x|y_i) \times P(y_i)$  ile orantılı. Ayrıca sınıfın ( $y_i$ )'nin varlığında  $x_1, x_2, \dots, x_n$  özelliklerinin birbirinden bağımsız olduğunu varsayalım. Tüm bunları birleştirirsek:

$$\hat{y} = \underset{i \in \{1, \dots, k\}}{\operatorname{argmax}} P(y_i|x)$$

$$\hat{y} = \underset{i \in \{1, \dots, k\}}{\operatorname{argmax}} P(y_i) \times P(x|y_i)$$

$$\hat{y} = \underset{i \in \{1, \dots, k\}}{\operatorname{argmax}} P(y_i) \times \prod_{j=1}^n P(x_j|y_i)$$

Yukarıdaki kural ile test örneklerini sınıflandıran sınıflandırıcıya 'Naive Bayes Sınıflandırıcı' denir.



ör.

<b>Deri</b>	<b>Renk</b>	<b>Büyükük</b>	<b>Et</b>	<b>Sınıf</b>
Tüylü	Kahverengi	Büyük	Sert	Güvenli
Tüylü	Yeşil	Büyük	Sert	Güvenli
Tüysüz	Kırmızı	Büyük	Yumuşak	Tehlikeli
Tüylü	Yeşil	Büyük	Yumuşak	Güvenli
Tüylü	Kırmızı	Küçük	Sert	Güvenli
Tüysüz	Kırmızı	Küçük	Sert	Güvenli
Tüysüz	Kahverengi	Küçük	Sert	Güvenli
Tüylü	Yeşil	Küçük	Yumuşak	Tehlikeli
Tüysüz	Yeşil	Küçük	Sert	Tehlikeli
Tüylü	Kırmızı	Büyük	Sert	Güvenli
Tüysüz	Kahverengi	Büyük	Yumuşak	Güvenli
Tüysüz	Yeşil	Küçük	Yumuşak	Tehlikeli
Tüylü	Kırmızı	Küçük	Yumuşak	Güvenli
Tüysüz	Kırmızı	Büyük	Sert	Tehlikeli
Tüysüz	Kırmızı	Küçük	Sert	Güvenli
Tüylü	Yeşil	Küçük	Sert	Tehlikeli

Eğitim  
Seti





Elimizde bu eğitim seti varken ‘Tüylü, Kırmızı, Büyük, Yumuşak’ özelliklere sahip bir hayvanı yemek güvenli midir yoksa tehlikeli midir?

$P(\text{güvenli} | \text{tüylü, kırmızı, büyük, yumuşak})$  **Vs**  $P(\text{tehlikeli} | \text{tüylü, kırmızı, büyük, yumuşak})$

$P(\text{güvenli} | \text{tüylü, kırmızı, büyük, yumuşak}) \propto$   
 $P(\text{tüylü, kırmızı, büyük, yumuşak} | \text{güvenli}) \times P(\text{güvenli})$

Eğitim setindeki 16 hayvandan 10’u güvenli sınıfındadır. O halde  $P(\text{güvenli}) = \frac{10}{16} = 0,62$ .

Şartlı bağımsız varsayımı sayesinde:

$P(\text{tüylü, kırmızı, büyük, yumuşak} | \text{güvenli}) =$   
 $= P(\text{tüylü} | \text{güvenli}) \times P(\text{kırmızı} | \text{güvenli}) \times P(\text{büyük} | \text{güvenli}) \times P(\text{yumuşak} | \text{güvenli})$



Deri	Renk	Büyüklik	Et	Sınıf
<u>Tüylü</u>	Kahverengi	<u>Büyük</u>	Sert	<b>Güvenli</b>
<u>Tüylü</u>	Yeşil	<u>Büyük</u>	Sert	<b>Güvenli</b>
Tüysüz	Kırmızı	Büyük	Yumuşak	<b>Tehlikeli</b>
<u>Tüylü</u>	Yeşil	<u>Büyük</u>	<u>Yumuşak</u>	<b>Güvenli</b>
<u>Tüylü</u>	<u>Kırmızı</u>	Küçük	Sert	<b>Güvenli</b>
Tüysüz	<u>Kırmızı</u>	Küçük	Sert	<b>Güvenli</b>
Tüysüz	Kahverengi	Küçük	Sert	<b>Güvenli</b>
Tüylü	Yeşil	Küçük	Yumuşak	<b>Tehlikeli</b>
Tüysüz	Yeşil	Küçük	Sert	<b>Tehlikeli</b>
<u>Tüylü</u>	<u>Kırmızı</u>	<u>Büyük</u>	Sert	<b>Güvenli</b>
Tüysüz	Kahverengi	<u>Büyük</u>	<u>Yumuşak</u>	<b>Güvenli</b>
Tüysüz	Yeşil	Küçük	Yumuşak	<b>Tehlikeli</b>
<u>Tüylü</u>	<u>Kırmızı</u>	Küçük	<u>Yumuşak</u>	<b>Güvenli</b>
Tüysüz	Kırmızı	Büyük	Sert	<b>Tehlikeli</b>
Tüysüz	<u>Kırmızı</u>	Küçük	Sert	<b>Güvenli</b>
Tüylü	Yeşil	Küçük	Sert	<b>Tehlikeli</b>

Güvenli sınıfındaki 10 hayvandan 6'sı tüylüdür.  $P(\text{tüylü}|\text{güvenli}) = \frac{6}{10} = 0,6$ .

Güvenli sınıfındaki 10 hayvandan 5'i kırmızıdır.  $P(\text{kırmızı}|\text{güvenli}) = \frac{5}{10} = 0,5$ .

Güvenli sınıfındaki 10 hayvandan 5'i büyüktür.  $P(\text{büyük}|\text{güvenli}) = \frac{5}{10} = 0,5$ .

Güvenli sınıfındaki 10 hayvandan 3'ü yumuşaktır.  $P(\text{yumuşak}|\text{güvenli}) = \frac{3}{10} = 0,3$ .



$$P(\text{güvenli}|\text{tüylü, kırmızı, büyük, yumuşak}) \propto$$

$$P(\text{tüylü}|\text{güvenli}) \times P(\text{kırmızı}|\text{güvenli}) \times P(\text{büyük}|\text{güvenli}) \times P(\text{yumuşak}|\text{güvenli}) \times P(\text{güvenli})$$

$$= 0,6 \times 0,5 \times 0,5 \times 0,3 \times 0,62 = 0,0279.$$

Benzer şekilde  $P(\text{tehlikeli}|\text{tüylü, kırmızı, büyük, yumuşak})$  yi hesaplayalım.

$$P(\text{tehlikeli}|\text{tüylü, kırmızı, büyük, yumuşak}) \propto$$

$$P(\text{tüylü}|\text{tehlikeli}) \times P(\text{kırmızı}|\text{tehlikeli}) \times P(\text{büyük}|\text{tehlikeli}) \times P(\text{yumuşak}|\text{tehlikeli}) \times P(\text{tehlikeli})$$

$$= 0,33 \times 0,33 \times 0,33 \times 0,5 \times 0,38 = 0,006.$$

$$P(\text{güvenli}|\text{tüylü, kırmızı, büyük, yumuşak}) > P(\text{tehlikeli}|\text{tüylü, kırmızı, büyük, yumuşak})$$

olduğundan test örneğini güvenli olarak sınıflandırırız. Yani ‘*Tüylü, Kırmızı, Büyük, Yumuşak*’ özelliklere sahip bir hayvanı yemek güvenlidir.



## Naive Bayes Sınıflandırıcıda Dikkat Edilecek Hususlar

1. Bir değer bir sınıfta hiç görülmemiş olabilir.

Örneğin kahverengi bir hayvan Tehlikeli sınıfında hiç görülmemiştir (verilen eğitim setinde böyle bir örnek yoktur). Bu durumda  $P(\text{kahverengi}|\text{tehlikeli}) = 0$  olur. Yani kahverengi bir hayvanın tehlikeli olma olasılığı direkt 0 olur. Diğer hiçbir özellik dikkate alınmaz. Bu ise çoğu kez hatta yapmamıza neden olur.

Basit bir çözüm olarak böyle bir durumda 0 yerine çok küçük bir olasılık verebiliriz. Örneğin 0.0000001 gibi.

2. Genel olarak olasılıkları çarpmak iyi bir fikir değildir.

Bir veri setinde 10000 tane özellik olduğunu düşünün:  $X_1, X_2, \dots, X_{10000}$ .

$P(X_1|y_i) \times P(X_2|y_i) \times \dots \times P(X_{10000}|y_i)$  çarpımı çok çok küçük bir sayı olabilir, örneğin  $10^{-20000}$  gibi. Bu durumda kullandığımız program bunu 0'a çevirebilir. Böylece test örneğini  $y_i$  sınıfına eşleştirme olasılığımız 0 olur.

Çözüm olarak çarpımın logunu alırız:

$$\hat{y} = \operatorname{argmax} \log \left( P(y_i) \times \prod_{j=1}^n P(x_j|y_i) \right)$$



## Sayısal Özellik Varken Naive Bayes Sınıflandırıcı

Özellikler kategorik iken Naive Bayes sınıflandırıcı inşa etmek oldukça kolaydır. Fakat sayısal özellikler varken  $P(x|y)$  olasılığını hesap etmek pek kolay değildir.

Bu durumda genel yaklaşım *sayısal özelliklerdeki değerlerin her bir sınıf için normal dağılıma sahip olduğunu varsaymaktır.*

ör.

Ev Sahibi	Yıllık Gelir	Krediyi ödemiş mi?
Evet	125K	Evet
Hayır	100K	Hayır
Hayır	70K	Hayır
Evet	120K	Hayır
Hayır	105K	Evet
Hayır	60K	Hayır
Evet	220K	Evet



Eđitim seti yukaridaki gibi verilmisken *ev sahibi olmayan ve yıllık geliri 100K* olan bir test örneğinin alacağı krediyi ödeme olasılığını ve odememe olasılığını karşılaştıralım.

$$P(\text{Evet}|\text{Ev sahibi değil, 100K}) \text{ Vs } P(\text{Hayır}|\text{Ev sahibi değil, 100K})$$

$$P(\text{Evet}|\text{Ev sahibi değil, 100K}) \propto P(\text{Ev sahibi değil, 100K}|\text{Evet}) \times P(\text{Evet})$$

$$P(\text{Ev sahibi değil, 100K}|\text{Evet}) = P(\text{Ev sahibi değil}|\text{Evet}) \times P(100\text{K}|\text{Evet}) \times P(\text{Evet})$$

Aldığı krediyi odeyen 3 kişi vardır. Bu üç kişinin birinin evi yoktur; ikisinin evi vardır.

$$P(\text{Ev sahibi değil}|\text{Evet}) = \frac{1}{3} = 0,33$$

$P(100\text{K}|\text{Evet})$  olasılığını hesaplarken; krediyi ödeyen kişilerin gelirlerinin normal dağılıma sahip olduğunu varsayacağız. Yani krediyi odeyen kişilerin gelirleri:

125, 105,220

normal dağılıma sahip olsun.



Bu dagilimin ortalamasi  $\mu = 150$ , standart sapması  $\sigma = 61,4$

Bir  $x$  deęerinin ortalamasi  $\mu$ , standart sapması  $\sigma$  olan bir normal dagilim tarafından üretilme olasılıęı  $P(x|\mu, \sigma)$  řu formülle hesaplanır:

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

Bu formulde  $x = 100$ ,  $\mu = 150$  ve  $\sigma = 61,4$  deęerleri yerlerine konursa:

$$P(100K|Evet) = P(100|150,61.4) = 0.0047$$

$$P(Ev sahibi degil, 100K|Evet) \propto 0.33 \times 0.0047 \times 0.42 = 0.00651$$

$$P(Ev sahibi degil, 100K|Hayır) \propto 0.75 \times 0.013 \times 0.57 = 0.056$$

○ halde test örneğindeki kisinin alacağı krediyi odememe olasılığı daha yüksektir.



## Lojistik Regresyon

Elimizde bir *ikili sınıflandırma* (yalnızca iki tane sınıfın olduğu sınıflandırma) eğitim seti olsun. Eğitim setindeki sınıflardan birini 0, diğer sınıfı 1 olarak etiketleyelim. Böylece bağıli deęişken sayısal (nümerik) deęerler almış olur. Bu bize sınıflandırma problemini regresyon problemine dönüştürmemizi sağlar.

ör.

Tümör Büyüklüğü	Kanser?
0.3	Kanser deęil
4.8	Kanser
5	Kanser
1.5	Kanser deęil
0.7	Kanser deęil
1	Kanser deęil
5.2	Kanser

Sınıflandırma Problemi

0/1 dönüştürmesi



Tümör Büyüklüğü	Kanser?
0.3	0
4.8	1
5	1
1.5	0
0.7	0
1	0
5.2	1


Regresyon Problemi






# Lojistik Regresyon

Tümör Büyüklüğü	Kanser?
0.3	0
4.8	1
5	1
1.5	0
0.7	0
1	0
5.2	1



Verilen ikili sınıflandırma problemini regresyon problemine dönüştürsek ve klasik anlamda bir regresyon doğrusu oluşturursak ( $y = w_0 + w_1x$ ) elde edeceğimiz  $y$  değerlerinin  $[0,1]$  arasında olmasını garanti edemeyiz.






$y = w_0 + w_1 x$  değerlerini 0-1 aralığına sığdırmak için bu değerleri lojistik (sigmoid) fonksiyonuna sokarız. Lojistik fonksiyon:

$$\sigma: \mathbb{R} \rightarrow [0,1]$$

$$\sigma(y) = \frac{e^y}{1 + e^y}$$

şeklindedir; aldığı her değeri [0,1] aralığında bir yere eşler.





Her zaman  $[0,1]$  aralığında!!

Lojistik fonksiyon ile regresyonu birleştirerek lojistik regresyon sınıflandırıcısı elde ederiz. Bu sınıflandırıcı  $x = (x_1, \dots, x_n)$  örneğini

$$f(x) = \sigma(w_0 + w_1x_1 + \dots + w_nx_n) = \frac{e^{w_0 + w_1x_1 + \dots + w_nx_n}}{1 + e^{w_0 + w_1x_1 + \dots + w_nx_n}}$$

fonksiyonu ile  $[0,1]$  arası bir değere eşler. Bu değer  $x$  örneğinin pozitif sınıfa ( $Y = 1$ ) ait olma olasılığıdır.

$$P(Y = 1|x) = \frac{e^{w_0 + w_1x_1 + \dots + w_nx_n}}{1 + e^{w_0 + w_1x_1 + \dots + w_nx_n}}$$



Doğal olarak, örneğin negatif sınıfa ait olma olasılığı

$$P(Y = 0|x) = 1 - P(Y = 1|x)$$

şeklinde hesaplanır.

Eğer olasılıklarla değil, direkt pozitif-negatif (kanser- kanser değil) sınıflarıyla ilgileniyorsak  $P(Y = 1|x) \geq 0.5$  durumunda  $x$  örneğini pozitif;  $P(Y = 1|x) < 0.5$  ise  $x$  örneğini negatif olarak tahmin ederiz.

## Lojistik Regresyon Maliyet Fonksiyonu

Diyelimki eğitim setimizde  $m$  tane örnek olsun. Her bir örnek

$$(x^i, y^i) \text{ öyleki } x^i = (x_1^i, x_2^i, \dots, x_n^i) \text{ ve } y^i \in \{0,1\}$$

$i \in \{1, \dots, m\}$  formundadır.

$x^i$ , nin sınıfı  $w_0, w_1, \dots, w_n$  katsayıları varken lojistik regresyonla

$$\sigma(w_0 + w_1 x_1^i + \dots + w_n x_n^i)$$

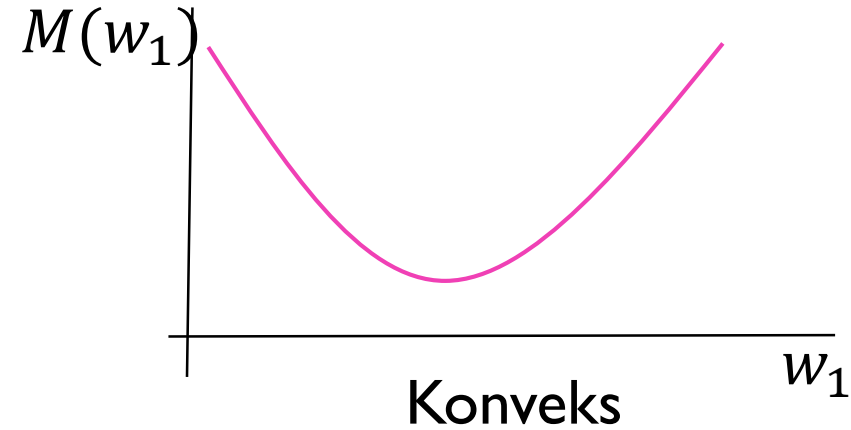
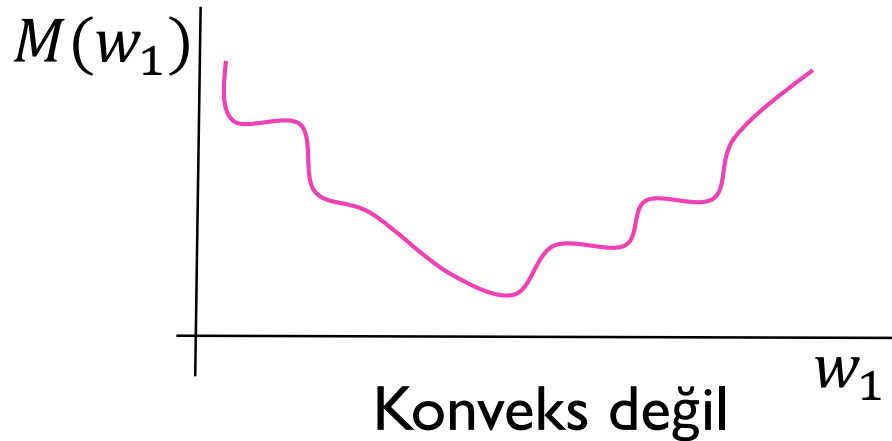
olarak tahmin edilir.



Lineer regresyonda olduğu gibi her  $(x^i, y^i)$  örneği için tahmin edilen değer  $\sigma(w_0 + w_1x_1^i + \dots + w_nx_n^i)$  ile gerçek değer  $y^i$  arasındaki farkın karesini alarak oluşturacağımız maliyet fonksiyonu şöyle olur:

$$M(w_0, w_1, \dots, w_n) = \frac{1}{2m} \sum_{i=1}^m (\sigma(w_0 + w_1x_1^i + \dots + w_nx_n^i) - y^i)^2$$


Fakat bu fonksiyon konveks değildir; bir çok lokal minimum içerir. Bu durumda bu fonksiyonu minimize eden  $w_0, w_1, \dots, w_n$  değerlerini hesaplamak için gradient descent algoritmasından faydalanamayız.



Gerçek sınıfı 1 olan bir  $x^i$  örneğinin

- i. sınıfını 0 olarak tahmin edersek maliyetin çok büyük olması gerekir;
- ii. sınıfını 1 olarak tahmin edersek maliyetin çok küçük olması gerekir.

$[0,1]$  aralığında; 0'da maksimum; 1'de minimum değerini alan konveks fonksiyon  $-\log x$  fonksiyonudur.



Lojistik regresyonda  $x^i$  örneği için sınıf tahminimiz  $\sigma(w_0 + w_1 x_1^i + \dots + w_n x_n^i)$  idi. Bu tahmine göre maliyet değişir. O yüzden maliyeti veren  $-\log$  fonksiyonu

$\sigma(w_0 + w_1 x_1^i + \dots + w_n x_n^i)$  değerinin bir fonksiyonudur.




Şu halde  $y^i = 1$  iken maliyet:  $-\log(\sigma(w_0 + w_1x_1^i + \dots + w_nx_n^i))$  olur. (1)

Gerçek sınıfı 0 olan bir  $x^i$  örneğinin

- i. sınıfını 1 olarak tahmin edersek maliyetin çok büyük olması gerekir;
- ii. sınıfını 0 olarak tahmin edersek maliyetin çok küçük olması gerekir.

$[0,1]$  aralığında; 0'da minimum; 1'de maksimum değerini alan konveks fonksiyon  $-\log(1 - x)$  fonksiyonudur.



$y^i = 0$  iken maliyet:  $-\log(1 - \sigma(w_0 + w_1x_1^i + \dots + w_nx_n^i))$  olur. (2)



(1) ve (2) deki maliyetleri birleştirecek:

$$-y^i \cdot \log(\sigma(w_0 + w_1 x_1^i + \dots + w_n x_n^i)) - (1 - y^i) \cdot \log(1 - \sigma(w_0 + w_1 x_1^i + \dots + w_n x_n^i))$$

olur. Şu halde ortalama maliyet:

$$M(w_0, w_1, \dots, w_n) = \frac{1}{2m} \sum_{i=1}^m -y^i \cdot \log(\sigma(w_0 + w_1 x_1^i + \dots + w_n x_n^i)) - (1 - y^i) \cdot \log(1 - \sigma(w_0 + w_1 x_1^i + \dots + w_n x_n^i))$$

Maliyet fonksiyonun  $w_0$ 'a göre türevi

$$\frac{\partial M}{\partial w_0} = \frac{1}{m} \sum_{i=1}^m \sigma(w_0 + w_1 x_1^i + w_2 x_2^i + \dots + w_n x_n^i) - y^i$$

Maliyet fonksiyonun  $w_j$ 'ye göre türevi

$$\frac{\partial M}{\partial w_j} = \frac{1}{m} \sum_{i=1}^m (\sigma(w_0 + w_1 x_1^i + w_2 x_2^i + \dots + w_n x_n^i) - y^i) x_j^i$$

Bulduğumuz bu türevler gradient descent algoritmasında  $w_j$  güncellemesinde

$$w_j' := w_j - \alpha \cdot \frac{\partial M}{\partial w_j}$$



yerine konur.



## Lojistik Regresyon İcin Gradient Descent Algoritması

**Giris:** başlangıç vektörü,  $M = M(w_0, w_1, \dots, w_n)$  fonksiyonu  
 $\alpha$  öğrenme oranı, maxIter maksimum iterasyon sayısı

**Cikis:** Optimize edilmiş  $w$  vektörü

**for** i=1:maxIter

$$w'_0 := w_0 - \alpha \cdot \frac{1}{m} \sum_{i=1}^m \sigma(w_0 + w_1 x_1^i + w_2 x_2^i + \dots + w_n x_n^i) - y^i$$

**for** j=1:n

$$w'_j := w_j - \alpha \cdot \frac{1}{m} \sum_{i=1}^m (\sigma(w_0 + w_1 x_1^i + w_2 x_2^i + \dots + w_n x_n^i) - y^i) x_j^i$$

**end for**

$(w_0, w_1, \dots, w_n) \leftarrow (w'_0, w'_1, \dots, w'_n)$  // w'ları aynı anda güncelle

**end for**

