

# Shannon Bilgi Kuramı

Çağatay Yücel

Yaşar Üniversitesi  
Bilgisayar Mühendisliği

08.03.2012 / Shannon Bilgi Kuramı

# İçerik

- 1 Giriş
- 2 Bilgi Kuramının Tarihi
  - Harry Nyquist, (1924)
  - Ralph Hartley, (1928)
  - Claude Elwood Shannon, (1948)
- 3 Temel Olasılık Bilgileri
- 4 Belirsizlik, Entropi ve Shannon'ın Modeli
  - Ortak, Koşullu ve Marjinal Entropi
  - Karşılıklı Bilgi
- 5 Shannon - Weaver İletişim Modeli
- 6 Belleksiz kesikli bilgi kaynağı
- 7 Bellekli kesikli bilgi kaynağı
- 8 İletişim Kanalı Kapasitesi
- 9 Bilgi Kuramı Örnek Uygulama Alanları
  - Veri sıkıştırma
  - Kriptografi
- 10 Kolmogorov Karmaşası ve Shannon Entropisi

# Bilgi Kuramı ve Kavramı

- Bilgi kavramı ile uğraşan, bilgiyi ölçmeye çalışan ve kullanım alanlarını inceleyen bilim alanına *bilgi kuramı* denilebilir.
- Genel bakış açısıyla, bilgi kavramı 3'e ayrılır:
  - Sözdizimsel Bilgi: Mesajları oluşturan semboller ve bu sembollerin arasındaki ilişkileri ile alakalıdır.  
Örn: Gramer kurallarının tamamı, Büyük ünlü uyumu.
  - Anlamsal Bilgi: Mesajların ne anlama geldiği ile ilgilenir.
  - İşlevsel Bilgi: Mesajların nasıl kullanıldığı ve etkileri üzerinedir.

# Shannon Bilgi Kuramı

- Bilginin sözdizimsel olarak incelendiği ve modellendiği kuramdır.
- İstatistiksel Bilgi Kuramı veya İletişim Kuramı olarak da anılır.
- Claude E. Shannon'ın 1948'de yayınladığı "A Mathematical Theory of Communication" makalesi ile temelleri atılmıştır.
- Bu kuramın oluşumundaki tarihsel sürece kısaca bir göz atalım.

## Harry Nyquist, (1924)

- “Certain Factors Affecting Telegraph Speed (1924)” adlı makalesi ile telgraf üzerinden maksimum hızda ve bozulma olmadan mesaj göndermenin yolunu açıkladı.
- Kullanılan devreye göre iletişim kanalının limitlerinin var olduğunu açıkladı.

## Ralph Hartley, (1928)

- “Transmission of Information (1928)” adlı makalesi ile ilk olarak bilgi ölçülmeye çalışılmıştır.
- $s$  karakterlik bir alfabemiz olsun ve  $n$  uzunluğundaki bir mesajın içerisindeki bilgi miktarı

$$H_H(s^n) = \log(s^n) = n \cdot \log(s)$$

olarak tanımlanmıştır.

- Bu durumda:

$$H_H(s^n) = n \cdot H_H(s^1)$$

## Claude Elwood Shannon, (1948)

- “A Mathematical Theory of Communication (1948)”
- Nyquist ve Hartley'nin kuramlarını genişleterek günümüz bilgi kuramını oluşturmuştur.
- Bir mesajın içerisindeki belirsizliği olasılık kavramı ile ilişkilendirerek mesajın içerisindeki bilgi miktarını tanımlamıştır.
- Tüm karakterlerin oluşma olasılıklarının eşit olduğu varsayıldığında Hartley'nin ölçüsüne dönülmektedir. Bu sebeple Hartley'nin ölçüsü Shannon ölçüsünün özel bir durumudur denilebilir.

# Temel Olasılık Bilgileri

- $X = x_1, x_2, \dots, x_n$  - deneyini ele alalım.  $x_i$  olası sonuçlar olsun.
- $P = p_1, p_2, \dots, p_n$  - örnek uzaydaki olayların ortaya çıkma olasılıkları olsun.

## Tanım

Eğer aşağıdaki koşullar sağlanıyor ise  $P = p_1, p_2, \dots, p_n$  bir olasılık dağılımıdır :

- 1  $p_i \geq 0$
- 2  $\sum p_i = 1$



# Ortak Olasılık

- $Y = y_1, y_2, \dots, y_m$
- $Q = q_1, q_2, \dots, q_m$
- $(X, Y) = (x_1, y_1), \dots, (x_n, y_m)$  olayını tek bir örnek uzay olarak tanımlayabiliriz.

## Tanım

$(x_i, y_i)$  sonucunun ortaya çıkma olasılığına *ortak olasılık* denir ve  $r(x_i, y_i)$  ile gösterilir.

# Marjinal Olasılık

- Ortak olasılık biliniyor ise, marjinal olasılıklar hesaplanabilir.

## Tanım

$r_{ij}$  ortak olasılık dağılışı olsun. Bu durumda marjinal dağılışlar,  $p_i, q_j$ :

$$p_i = \sum_{j=1}^m r_{ij}$$

$$q_j = \sum_{i=1}^n r_{ij}$$

## Koşullu - Marjinal- Ortak olasılık

- $X$  olayının, bir diğer  $Y$  olayına koşullu olasılığı (veya  $Y$  biliniyorken  $X$ 'in olasılığı),  $P(X|Y)$  olarak tanımlanır;
- Koşullu olasılık, ortak olasılık ve marjinal olasılıklar arasında aşağıdaki gibi bir ilişki vardır.

$$r(x_i, y_j) = q(y_j) \cdot p(x_i|y_j) = p(x_i) \cdot q(y_j|x_i)$$

# Birbirinden Bağımsız Olaylar

- $X, Y$  olaylarının birbirinden bağımsız olması durumunda:

$$p(x_i|y_j) = p(x_i)$$

$$q(y_j|x_i) = q(y_j)$$

$$r(x_i, y_j) = p(x_i) \cdot q(y_j)$$

formülleri geçerlidir.

## Mesajdaki Belirsizlik ve Bilgi Miktarı

- Bir mesajdaki belirsizliğin o mesajdaki bilgi miktarına eşit olduğunu aşağıdaki örnekle açıklayalım.
- Bir torbaya her renkten toptan bir adet attığımızda, herhangi bir rengin gelme olasılığı  $1/n$  olur.
- Çekilen bir topun hangi renk olacağı belirsizdir ve çekilişin ardından sonuç bize bir miktar bilgi vermektedir.
- Sadece tek bir renkten  $n$  adet top atılsa idi, çekilen topun rengini zaten biliyor olduğumuzdan bu çekilişin ardından herhangi bir şey öğrenmemiş olurduk.
- Böylelikle belirsizliğin bilgi miktarına eşit olduğunu düşünebiliriz.

# Bilgi Miktarı

## Tanım

$X$  bir olasılık deneyi olsun.  $p(x_i)$  ise  $x_i$  sonucunun ortaya çıkması durumunun olasılığı olarak verildiğinde, bu deneydeki ortalama bilgi miktarı:

$$H(X) = - \sum_{i=1}^n p(x_i) \cdot \log(p(x_i)) = - \sum_{i=1}^n p_i \log(p_i)$$

# Bilgi Miktarı

- Logaritmanın tabanı 2 olarak seçildiğinde, bilgi miktarının birimi bit olmaktadır.
- $\log(1) = 0$  olduğundan kesin olarak gerçekleşeceğini bildiğimiz bir olay bize 0 bitlik bilgi vermektedir.
- Tüm olasılıklar eşit olduğunda ise bilgi miktarı maksimum değerini almaktadır.
- Denklemdaki - işareti bilgi miktarı için  $H(X) \geq 0$  koşulunu yerine getirir.


# Aksiyomlar

- $H(X)$  süreklidir.
- $H(X)$  simetriktir.
- $H(X)$  için toplama özelliği vardır.
- $H(X)$ ,  $X$  olayı uniform dağılışı gösterdiğinde maksimum değerini alır.



# Süreklilik

- $H(X)$ ,  $p$ 'de süreklidir.
- $p = (p, 1 - p)$



# Simetri

- Olasılıkların sıralanışının bir önemi yoktur.

- Örneğin:

$X = (\text{Kırmızı top çekilir, Mavi top çekilir})$

$P_x = (0.8, 0.2)$  için

$$H(X) = -0.8 \cdot \log(0.8) - 0.2 \cdot \log(0.2) = 0.72 \text{ bit.}$$

$Y = (\text{Kar yağar, Kar yağmaz})$

$P_y = (0.2, 0.8)$  için

$$H(Y) = -0.2 \cdot \log(0.2) - 0.8 \cdot \log(0.8) = 0.72 \text{ bit.}$$

# Toplama Özelliğinin Sağlanması

- Birbirinden bağımsız iki olay  $X, Y$  için:

$$H(X, Y) = H(X) + H(Y)$$

- Örneğin:

İki zar atıldığında, birbirinden bağımsız olaylar söz konusu olduğu için, beraber atılmaları ile birinin diğerinden sonra atılmasının bir farkı yoktur.

$$H(X) = H(Y)$$

$$H(p_1, q_1, \dots, p_6, q_1, \dots, p_6, q_6) = H(p_1, p_2, \dots, p_6) + H(q_1, q_2, \dots, q_6)$$

# Entropinin Maksimum ve Minimum Olma Durumları

## Teorem

$X = (x_1, \dots, x_n)$  örnek uzayımız olsun.  $P = (p_1, \dots, p_n)$  ise  $X$  örnek uzayına karşılık gelen olasılık dağılımımız olsun.


- 1  $H(X) \leq \log(n)$ , eşitlik durumu  $= p_i = 1/n$
- 2  $H(X) \geq 0$ , eşitlik durumu  $= p_k = 1$  değerini sağlayan bir  $k$  değeri mevcuttur.

İspat için [1]

# Örnek: Taralı alanı tahmin etmek

1	2	3	4
5	6	7	8
9	10	11	12
13	14	15	16

- Tüm karelerin taralı olma olasılıklarının eşit olduğunu varsayarsak:
- Minimum 4 soru sorarak taralı alanı bulabiliriz.
- $H(X) = -\sum_{i=1}^{16} \frac{1}{16} \cdot \log\left(\frac{1}{16}\right) = 4\text{bit}$



## Ortak, Koşullu ve Marjinal Entropi

### Tanım

$(X, Y)$  raslantısal iki boyutlu vektörel değişkenimiz olsun.  $r_{ij}$ ,  $x_i$  ve  $y_j$  sonuçlarının ortaya çıkma olasılığı ise, *Ortak (joint) Bilgi Miktarı*

$$H(X, Y) = - \sum_{i=1}^n \sum_{j=1}^m r_{ij} \cdot \log(r_{ij})$$

### Tanım

$(X, Y)$  raslantısal iki boyutlu vektörel değişkenimiz olsun.  $r_{ij}$ ,  $x_i$  ve  $y_j$  sonuçlarının ortaya çıkma olasılığı,  $q$ ,  $Y$ 'nin marjinal olasılığı ise  $H(Y|X)$ ,  $Y$ 'nin  $X$  olayına bağlı, yani *Koşullu Bilgi Miktarı*:

$$H(Y|X) = - \sum_{i=1}^n \sum_{j=1}^m r_{ij} \cdot \log(q(y_j|x_i))$$

# Ortak, Koşullu ve Marjinal Entropi

## Teorem

$H(Y|X)$  koşullu bilgi miktarı olsun.

- $H(Y|X) \geq 0$
- $H(Y|X) \leq H(Y)$  ve eşitlik durumu ancak  $X$  ve  $Y$  bağımsız ise gerçekleşir.

## Teorem

$H(Y|X)$  koşullu,  $H(X)$ ,  $H(Y)$  marjinal ve  $H(X, Y)$  ortak bilgi miktarları olsun.

$$H(X, Y) = H(X) + H(Y|X) = H(Y) + H(X|Y)$$

İspatları [1]'de bulabilirsiniz.

# Karşılıklı Bilgi Miktarı

## Tanım


$X$  ve  $Y$ 'ye bağlı *karşılıklı bilgi miktarı* aşağıdaki gibi tanımlanır.

$$I(X : Y) = H(Y) - H(Y|X) = \sum_{i=1}^n \sum_{j=1}^m r_{ij} \cdot \log\left(\frac{r_{ij}}{p_i \cdot q_j}\right)$$


- $Y$  ve  $X$  arasındaki bağımlılık miktarının ölçütüdür.
- $X, Y$  bağımsız değişkenler ise  $I(X : Y) = 0$  dır.
- $Y, X$ 'e tamamen bağımlı ise;  $H(Y|X) = 0$  ve  $I(X : Y) = H(Y)$ .



# Bilgi Miktarları Arasındaki İlişki

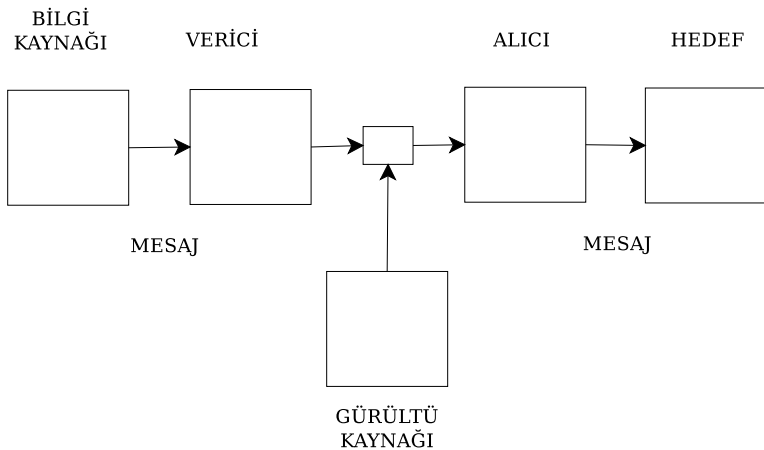


GENEL DURUM

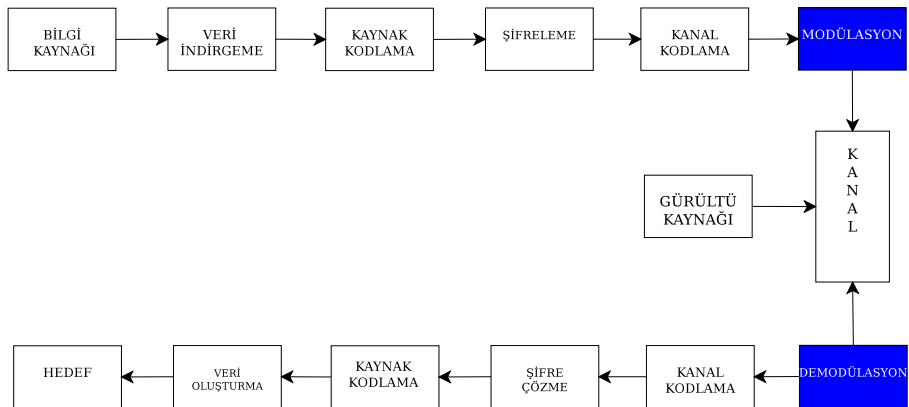


Bağımsız Olayların Entropisi

# Shannon - Weaver İletişim Modeli



# Detaylı İletişim Modeli



## Belleksiz Kesikli Bilgi Kaynağı

- Bir bilgi kaynağının alfabetini, sonlu sayıda sembolden oluşan bir küme olarak düşünebiliriz.
- $U = (u_1, u_2, \dots, u_n)$
- Mesaj veya kelime ardarda gelen bir grup sembolden oluşmaktadır. Alfabede  $n$  sembol varsa ve mesajımızın uzunluğu  $l$  sembol ise  $n^l$  adet olası mesaj oluşturabiliriz.
- Bilgi kaynağımızın stokastik olması, alfabedeki her sembol ile ilintili bir oluşma olasılığının,  $p(u_i) = p_i$ , var olması anlamına gelmektedir.
- Bu durumda, bu bilgi kaynağı tarafından üretilen bilgi miktarı, aşağıdaki formül ile bulunabilir.

$$H(U) = -p_i \cdot \log(p_i) \text{ bit/sembol}$$

- Maksimum üretilbileceğimiz bilgi miktarı ise:

$$\max[H(U)] = \log(n) \text{ bit/sembol}$$

# Fazlalık (Redundancy) Kavramı

## Tanım

Bir bilgi kaynağındaki fazlalık

$$Red = 1 - \frac{H(U)}{\max[H(U)]} = 1 - \frac{H(U)}{\log(n)}$$

ile gösterilir. Formüldeki  $n$  kaynak alfabedeki olası sembol sayısıdır.

# Kaynak Kodlama

- $U = (u_1, u_2, \dots, u_n)$  alfabetini kullanarak mesaj üreten bir kaynağımız olduğunu varsayalım ve mesajların bir iletişim kanalına yazıldığını düşünelim.
- Verimliliği sağlamak adına mesajların mümkün olduğunca fazlalıklardan kurtulması gerekir.
- Üretilen mesajın fazlalıklardan kurtulmasını sağlamak adına yeni bir alfabe ile kodlanmasına *kaynak kodlama* denir.

# Kaynak Kodlama

- $S = (s_1, s_2, \dots, s_n)$  kod alfabemiz olsun.
- $U$  alfabesinde üretilen her bir mesajın  $S$  alfabesinde bir karşılığı mevcuttur, bu karşılığa kod kelimesi (code word) denir.
- Eğer olası tüm kod kelimeler birbirinden farklıysa, bu kodlama tekniğine (non - singular) tekil olmayan kodlama denir.
- Kodlamanın başarılı bir şekilde geriye çevrilebilmesi için, her bir kod kelimesinin tek bir karşılığı olması gerekmektedir.
- Aynı zamanda kod sembollerinin okunduğu anda orjinal mesajın alfabesine çevrilebilmesine ani kodlama (instantaneous code) denir.

# Verimlilik

## Tanım

Bir kodlama tekniğinin verimliliği,  $\eta$ , aşağıdaki şekilde tanımlanır.

$$\eta = \frac{H(U)}{L \cdot \log(r)}$$

$H(U)$  mesajın kaynağının bilgi miktarı,  $L$  kod kelimelerinin ortalama uzunluğu ve  $r$  ise kod alfabesinin uzunluğudur.



# Huffman Kodlaması - Örnek

- Kayıpsız (lossless) olarak veriyi sıkıştırıp tekrar açmak için kullanılır.
- Huffman Kodlamasının en büyük avantajlarından birisi kullanılan karakterlerin frekanslarına göre bir ikili ağaç (binary tree) yapısında tutulmasıdır.
- Sık kullanılan karakterler daha kısa kod kelimelerle ifade edilip ağacın üst düğümlerinde yer alır.
- Nadir kullanılanlar ise daha uzun kelimelerle ifade edilip daha aşağıdaki düğümlerde yer alır.
- Örnek: Türkçe dilinde yapılan Huffman Kodlaması çalışması. . .

## Bellekli Kesikli Bilgi Kaynađı

- Belleksiz olma özelliđi bir çok dil için geçerli deđildir. Çođu zaman önceki karakterlerden bir sonraki karakterin tahmini yapılabilmektedir.
- Örn: *bilg* harflerini gördüğümüzde bir sonraki harfin çok büyük olasılıkla “i” olacağını tahmin edebiliriz.
- Bilgi kaynađımızın bellekli olması demek, o ana kadar kaynaktan gelen sembollerin bir sonraki sembolün olasılıklarını etkilemesi anlamına gelmektedir.
- Bellekli bilgi kaynakların ürettiđi diziler markov zincirleri ile gösterilebilir.

# Markov Zincirleri

## Tanım

$X_n, (n = 0, 1, 2, \dots, )$  sonlu sayıda değerler alan bir stokastik proses olsun.  $X_n = i$  notasyonu, prosesin  $n$  anında  $i$  değerinde olduğunu göstermektedir. Proses herhangi bir  $n$  anında  $i$  durumunda olduğunda, bir sonraki durumun  $j$  olma olasılığı sabittir.

$$P\{X_{n+1} = j | X_n = i, \dots, X_1 = i_1, X_0 = i_0\} = P_{ij}$$

$i, j$  ve  $n \geq 0$ .

Bu özelliği sağlayan proseslere *Markov Zinciri* denir.


- Markov zincirleri durum geçiş matrisleri ile ifade edilir.

## Örn: Markov Zincirleri

- Alfabemiz  $U = 0, 1, 2$  olsun.
- Durum geçiş matrisimiz ise şu şekilde olsun.

		Bir sonraki durum		
		0	1	2
Şu anki durum	0	0.65	0.28	0.07
	1	0.15	0.65	0.18
	2	0.12	0.36	0.52


## Örn: Markov Zincirleri



## Örn: İletişim Sistemi

- Bir ağ üzerinden 1 ve 0 gönderen bir iletişim sistemi düşünelim. Her bir adımda bir sonraki sembolün değişme olasılığı  $p$  olsun. Bu durumda geçiş matrisimiz şu şekildedir.

$$\begin{pmatrix} p & 1-p \\ 1-p & p \end{pmatrix}$$



# Chapman - Kolmogorov Denklemleri

- Bir prosesin  $n$  adımdan sonra durum değiştirme olasılıklarını Chapman - Kolmogorov denklemleri vermektedir.
- Bu denklemler

$$P_{ij}^{n+m} = \sum_{k=0}^{\infty} P_{ik}^n \cdot P_{kj}^m$$

tüm  $n, m \geq 0$  ve tüm  $i, j$  için sağlanır

## N. dereceden Markov Zincirleri

İletişim sistemini tekrardan değerlendirirsek,  $p = 0.7$  iken, 2. bitin ve 3. bitin olasılıklarını hesaplamak için:

$$P = \begin{vmatrix} 0.7 & 0.3 \\ 0.3 & 0.7 \end{vmatrix}$$

$$P^2 = P^{1+1} = P \cdot P$$

$$P^2 = \begin{vmatrix} 0.7 & 0.3 \\ 0.3 & 0.7 \end{vmatrix} \cdot \begin{vmatrix} 0.7 & 0.3 \\ 0.3 & 0.7 \end{vmatrix}$$

$$P^2 = \begin{vmatrix} 0.58 & 0.42 \\ 0.42 & 0.58 \end{vmatrix}$$

$$P^3 = P^2 \cdot P^1$$

$$P^3 = \begin{vmatrix} 0.58 & 0.42 \\ 0.42 & 0.58 \end{vmatrix} \cdot \begin{vmatrix} 0.7 & 0.3 \\ 0.3 & 0.7 \end{vmatrix}$$

$$P^3 = \begin{vmatrix} 0.532 & 0.468 \\ 0.468 & 0.532 \end{vmatrix}$$



# 1. Dereceden Markov Proseslerinin Bilgi Miktarı

- $u_i, i = 1, 2, \dots, m$  alfabemizdeki semboller olsun.
- $S_i, i = 1, 2, \dots, m$  prosesimizin durumları olsun.
- $u_{1i}$  durumundan  $u_{2j}$  durumuna geçiş durumunu düşünelim. Bu olasılığı  $p(u_{2j}|u_{1i})$  ile gösterirsek, bu geçişteki bilgi miktarı:


$$H(U_2|U_1) = - \sum_{i=1}^m \sum_{j=1}^m p(u_{2j}|u_{1i}) \cdot \log(p(u_{2j}|u_{1i})) \quad (1)$$

## N. Dereceden Markov Proseslerinin Bilgi Miktarı

- $n - 1$  önceki sembollerin bilindiği durumda, N. sembolün koşullu entropisi aşağıdaki gibi hesaplanır.

$$F_n(U) = H(U_n | U_{n-1}, U_{n-2}, \dots, U_1)$$

# İletişim Kanalı Kapasitesi



- Güvenilir bir şekilde bir iletişim kanalından gönderebileceğiniz maksimum bilgi miktarına *Operasyonel iletişim kanalı kapasitesi* denir.
- *Bilgi Kanalı İletişim Kapasitesi* ise şu şekilde tanımlanır.

$$C = \max_{\{p(x)\}} (I(X : Y))$$

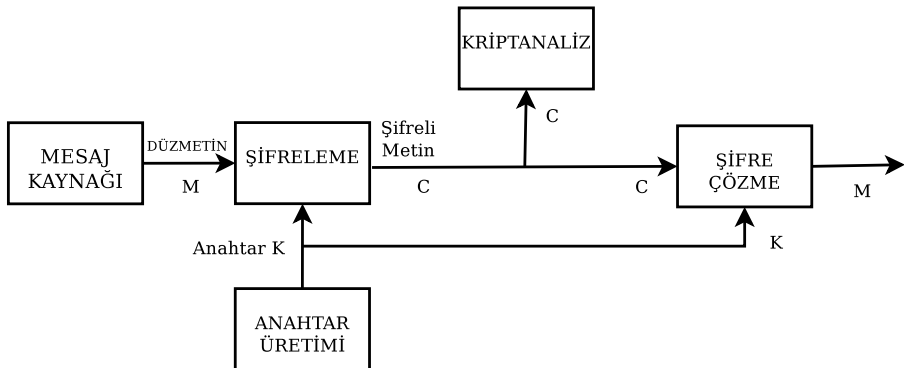
- Shannon'ın İletişim Kanalı Kodlama Teorisi'ne göre:

bilgi iletişim kapasitesi = operasyonel iletişim kapasitesi

# Veri Sıkıştırma

- Kayıpsız sıkıştırma algoritmaları
  - Huffman
  - Fano - Shannon
  - Arithmetic Coding
- Kayıplı sıkıştırma algoritmaları
  - JPEG, DJVU
  - MPEG 1-2-4,
  - MP2, MP3, WMA

# Simetrik Kriptosistemler



# Simetrik Kriptosistemler

- $M_i, H(M_i) = -\sum_{i=1}^n p(M_i) \cdot \log(p(M_i))$
- $C_i, H(C_i) = -\sum_{i=1}^n p(C_i) \cdot \log(p(C_i))$
- $K_i, H(K_i) = -\sum_{i=1}^n p(K_i) \cdot \log(p(K_i))$
- $H(K|C)$ , *key equivocation*

$$H(K|C) = -\sum_{h=1}^l \sum_{j=1}^m p(K_h, C_j) \cdot \log(p(K_h|C_j))$$

- $H(M|C)$ , *message equivocation* aynı şekilde hesaplanmaktadır.
- $H(M|C, K) = 0$  olmasını bekleriz.
- Kusursuz gizlilik için ideal olarak  $I(M : C) = 0$  olması gerekir.

# Kolmogorov Karmaşası

- 111111111111111111
- 1011010110101101

Hangisini daha karmaşık olarak nitelendirebiliriz?

# Kolmogorov Karmaşası

- 1111111111111111
- Yukarıdaki bit dizisi 16 adet 1 yazan Turing Makinesi ile ifade edilebilir.
- 1011010110101101
- Rasgele bit dizisi olarak nitelendirildiğinden tanımlayıcı Turing Makinesi bit dizisini sıkıştırmadan içermelidir.
- Kolmogorov Karmaşası ile bu fikri formal hale getirebiliriz.



# Kolmogorov Karmaşası

## Tanım

Bir  $x$  bit dizisinin Kolmogorov karmaşası,  $x$  bit dizisini üreten en küçük Turing Makinesi programının uzunluğuna eşittir.

$$K_f(x) = \min_p \{|p| : f(p) = x\}$$









“Algorithmic information theory is the result of putting Shannon’s information theory and Turing’s computability theory into a cocktail shaker and shaking vigorously.” —G. J. Chaitin

# Shannon Entropisi ve Kolmogorov Karmaşası

- Kolmogorov karmaşasının beklenen değeri bize Shannon Entropisini vermektedir.
- Kodlama teorisine göre mesajımız fazlalıkları azaltacak şekilde kodlanmaktadır. Bu kodlamayı Kolmogorov Karmaşasının tanımındaki  $f$  olarak değerlendirebiliriz.
- Bu durumda kodlama sisteminin beklenen değeri ile Shannon Entropisi arasındaki bağlantı kurulmuş olur.
- Formal teoremler ve ispatlar için [4]

Teşekkürler...

# References

-  [Jan C.A. van der Lubbe.](#)  
*Information Theory.*  
Cambridge Press, 1997.
-  [Kaan Kurtel.](#)  
Information theory lecture notes.
-  [Neil Conway.](#)  
Kolmogorov complexity lecture notes.
-  [Grunwald p. Vitanyi, P.](#)  
Shannon information and komogorov complexity.  
2010.
-  [C. E. Shannon.](#)  
A mathematical theory of communication.  
*Bell system technical journal*, 27, 1948.
-  [C. Shannon.](#)  
Communication theory of secrecy systems.  
*Bell System Technical Journal*, 28, 1949.
-  [Thomas M. Cover and Joy A. Thomas.](#)  
*Elements of information theory.*  
Wiley-Interscience, 1991.
-  [Sheldon M. Ross.](#)  
*Introduction to Probability Models.*  
Academic Press, New York, 10th edition, 2003.