



Οικονομικό Πανεπιστήμιο Αθηνών
Τμήμα Πληροφορικής
ΠΜΣ

Κρυπτογραφία και Εφαρμογές

Μαριάς Ιωάννης

marias@aub.gr

Μαρκάκης Ευάγγελος

markakis@gmail.com

■ Shannon theory

- ✓ Εντροπία
- ✓ Μελέτη κρυπτοσυστημάτων με θεωρία πληροφορίας
- ✓ Τέλεια μυστικότητα
- ✓ Πλεονασμός – Περίσσεια γλώσσας

■ Ανίχνευση γλώσσας

- ✓ Έλεγχος Κάπα
- ✓ Έλεγχος Χι

C. E. Shannon, Communication theory of secrecy systems,
Bell Systems Technical Journal, 656-715, 1949

✓ Cryptography via information theory

✓ Έστω X τυχαία μεταβλητή που παίρνει τιμές από ένα πεπερασμένο σύνολο $\{x_1, x_2, \dots, x_n\}$ με πιθανότητες $P(X = x_i) = p(x_i)$ όπου $0 \leq p(x_i) \leq 1$ για $i = 1, \dots, n$, και $\sum_i p(x_i) = 1$

✓ Αν Y επίσης τυχαία μεταβλητή, η απο κοινού κατανομή θα συμβολίζεται με $p(x_i, y_j) = P(X=x_i, Y=y_j)$

✓ Αν X, Y είναι ανεξάρτητες τυχαίες μεταβλητές τότε

$$p(x_i, y_j) = p(x_i) p(y_j), \text{ για κάθε } x_i, y_j$$

Δεσμευμένες πιθανότητες


- ✓ $p(x_i|y_j)$ = πιθανότητα η X να πάρει την τιμή x_i δεδομένου ότι η Y έχει την τιμή y_j
- ✓ $p(x_i|y_j) = p(x_i, y_j) / p(y_j)$, όταν $p(y_j) > 0$
- ✓ Αν X, Y είναι ανεξάρτητες τυχαίες μεταβλητές τότε
 $p(x_i|y_j) = p(x_i)$

- ✓ **Εντροπία:** μαθηματική απεικόνιση για το μέγεθος της πληροφορίας που παρέχεται από παρατήρηση της X
 - Η η αβεβαιότητα για την έκβαση πριν από την παρατήρηση της X
- ✓ **Ορισμός εντροπίας** (Πληροφορία κατά Shannon): Η ποσότητα της αβεβαιότητας μίας μεταβλητής X είναι:

$$H(X) = -\sum_i p(x_i) \log p(x_i) = \sum_i p(x_i) \log(1/p(x_i))$$

- ✓ **Ιδιότητες:**
 - $H(X) = 0$ iff $p(x_i) = 1$ για κάποιο i , και $p(x_j) = 0$ για κάθε $j \neq i$
 - Δεν υπάρχει αβεβαιότητα για το αποτέλεσμα
 - $H(X) = \log n$ iff $p(x_i) = 1/n$ για κάθε i , $1 \leq i \leq n$
 - Και οι n εκβάσεις, x_1, \dots, x_n , είναι ισοπίθανες

- ✓ **Παράδειγμα:** έστω τυχαία μεταβλητή X με σύνολο τιμών $\{0,1\}$ και $p(0) = a, p(1) = 1-a$.
- ✓ $H(X) = -a \log a - (1-a) \log(1-a)$
- ✓ Αν $a=0$ ή $a=1$, τότε $H(X)=0$
 - Δεν υπάρχει αβεβαιότητα για το αποτέλεσμα
- ✓ Για κάθε άλλη τιμή του a , η εντροπία είναι θετική και μεγιστοποιείται στο $a=1/2$
 - Εκεί που μεγιστοποιείται και ο βαθμός αβεβαιότητας



- ✓ Ομοίως ορίζεται η απο κοινού αβεβαιότητα:
 - $H(X, Y) = - \sum_i \sum_j p(x_i, y_j) \log p(x_i, y_j)$
- ✓ Καθώς και η υπο συνθήκη αβεβαιότητα:
 - $H(X|Y) = - \sum_i \sum_j p(x_i, y_j) \log p(x_i|y_j)$
- ✓ **Ιδιότητες:**
 - Αν X, Y ανεξάρτητες, τότε $H(X, Y) = H(X) + H(Y)$ (η αβεβαιότητα αθροίζεται)
 - Γενικά, $H(X, Y) \leq H(X) + H(Y)$
 - $H(X|Y) \leq H(X)$ (η αβεβαιότητα μειώνεται όσο μαθαίνουμε)
 - $H(X|Y, Z) \leq H(X|Y)$ (ομοίως)
 - $H(X, Z|Y) \geq H(X|Y)$ (αβεβαιότητα αυξάνεται όταν αυξάνεται το σύνολο των πιθανών ενδεχομένων)
 - **Αμοιβαία πληροφορία:** $I(X, Y) = H(X) - H(X|Y)$ (χρησιμοποιείται στη μέτρηση διαρροής πληροφορίας)


- Μελέτη κρυπτοσυστημάτων με θεωρία πληροφορίας
 - ✓ Έστω ένα τυχαίο κείμενο που θέλουμε να κρυπτογραφήσουμε και έστω ότι επιλέγουμε τυχαία ένα κλειδί με βάση κάποια κατανομή πιθανότητας
 - ✓ $P \rightarrow$ τυχαία μεταβλητή για την τιμή του plaintext
 - ✓ $K \rightarrow$ τυχαία μεταβλητή για την τιμή του κλειδιού
 - ✓ $C \rightarrow$ τυχαία μεταβλητή για την τιμή του ciphertext
 - ✓ Σε όλα τα συμμετρικά κρυπτοσυστήματα:
 - $H(C|P, K) = 0$ (αν ξέρω το απλό κείμενο και το κλειδί δεν υπάρχει αβεβαιότητα για το ciphertext)
 - $H(P|C, K) = 0$ (αν ξέρω το κρυπτοκείμενο και το κλειδί, μπορώ να αποκρυπτογραφήσω)

■ Τέλεια μυστικότητα (perfect secrecy)

- ✓ **Διαισθητικά:** ο Oscar δεν μπορεί να αποκτήσει κάποια πληροφορία για το plaintext (ή για το κλειδί) παρατηρώντας το ciphertext
- ✓ **Ορισμός:** Ένα κρυπτοσύστημα είναι *perfectly secure* ή *unconditionally secure against ciphertext-only attacks* αν $H(P|C) = H(P)$
- ✓ **Ισοδύναμα:** αν για κάθε πιθανή τιμή x για το P , και κάθε πιθανή τιμή y για το C : $\Pr(P = x|C=y) = \Pr(P=x)$

■ Τέλεια μυστικότητα (perfect secrecy)


- ✓ **Παράδειγμα:** έστω ότι έχουμε 3 σύμβολα απλού κειμένου, p_1 , p_2 , p_3 , που μπορούν να αντιστοιχιστούν σε 3 σύμβολα κρυπτοκειμένου ανάλογα με το κλειδί που διαλέγουμε



Ο Oscar βλέποντας το ciphertext δεν μπορεί να εξάγει κανένα συμπέρασμα για το plaintext

■ Τέλεια μυστικότητα (perfect secrecy)

✓ Αντιθέτως, αν το κρυπτοσύστημα ήταν:



✓ Όταν ο Oscar βλέπει c_1 ξέρει ότι το plaintext είναι p_1

✓ Μόνη αβεβαιότητα όταν βλέπει c_2

✓ Άρα δεν είναι perfectly secure

■ Τέλεια μυστικότητα (perfect secrecy)

- ✓ **Θεώρημα 1:** Έστω ότι στο shift cipher διαλέγουμε ισοπίθανα για κάθε σύμβολο του plaintext ένα τυχαίο κλειδί $k \in \mathbb{Z}_{26}$. Τότε για κάθε κατανομή πιθανότητας του plaintext, το κρυπτοσύστημα είναι perfectly secure
- ✓ **Θεώρημα 2:** Έστω ότι στο κρυπτοσύστημα one-time pad διαλέγουμε ισοπίθανα για κάθε m-bit string του plaintext ένα τυχαίο κλειδί $k \in \{0,1\}^m$. Τότε για κάθε κατανομή πιθανότητας του plaintext, το κρυπτοσύστημα είναι perfectly secure
 - Κάνοντας XOR με τυχαίο string, πετυχαίνουμε ότι $\Pr[C = y] = (1/2)^m$ για οποιοδήποτε m-bit string y

■ Τέλεια μυστικότητα (perfect secrecy)

- ✓ Έστω K ο χώρος των κλειδιών
- ✓ Όταν τα plaintext και ciphertext είναι ισομεγέθη (m-bit blocks), για κάθε κλειδί, η συνάρτηση κρυπτογράφησης είναι ένα bijection
- ✓ **Θεώρημα 3:** Όταν το plaintext, το ciphertext, και το κλειδί είναι ισομεγέθη και κάθε κλειδί επιλέγεται ισοπίθانا, το σύστημα έχει τέλεια μυστικότητα
 - Ιδέα απόδειξης: κάθε κλειδί προσδιορίζει ένα μοναδικό bijection,
 - Όταν το κλειδί επιλέγεται ισοπίθانا, ουσιαστικά επιλέγεται ένα τυχαίο bijection
 - άρα το ciphertext δεν μπορεί να μειώσει την αβεβαιότητα του plaintext

■ Τέλεια μυστικότητα (perfect secrecy)

- ✓ Ορισμός: Το *effective key size* του χώρου κλειδιών είναι $\log |\mathbf{K}|$ (= πόσα bits χρειαζόμαστε για να προσδιορίσουμε ένα κλειδί)
- ✓ Αν τα κλειδιά είναι ισοπίθانا, η *εντροπία* του χώρου κλειδιών, $H(\mathbf{K})$, ισούται με το effective key size
- ✓ Όταν τα plaintext και ciphertext είναι ισομεγέθη (m-bit blocks), τέλεια μυστικότητα έχουμε όταν η εντροπία του χώρου κλειδιών είναι $\log m$
- ✓ Τα συστήματα που παρέχουν τέλεια μυστικότητα είναι πρακτικά ανεφάρμοστα σήμερα
 - Τεράστιο μέγεθος κλειδιού
 - Κόστος παραγωγής, μετάδοσης, αποθήκευσης, επεξεργασίας
- ✓ Στόχος της κρυπτογραφίας: Σχεδιασμός συστημάτων με το καλύτερο trade-off ως προς:
 - Μέγεθος κλειδιού σχετικά μικρό (κρυπτογράφηση μεγάλων ακολουθιών χαρακτήρων χωρίς αλλαγή κλειδιού)
 - Μέγεθος κλειδιού σχετικά μεγάλο (για να μην μπορεί να σπάσει με brute force)
 - Ασφάλεια που να πλησιάζει την τέλεια μυστικότητα

■ Πλεονασμός – Περίσσεια Γλώσσας

- ✓ **Περίσσεια μίας γλώσσας (redundancy):** ποσοστό συνδυασμών γραμμάτων που δεν αντιστοιχούν σε μηνύματα που ανήκουν στη γλώσσα
 - Π.χ. στην ελληνική γλώσσα, με 4 χαρακτήρες, το «χέρι» είναι έγκυρη λέξη αλλά το «ουγκ» δεν είναι
- ✓ **Απόλυτος ρυθμός γλώσσας (absolute rate):** $A = \lceil \log(n) \rceil$, όπου n το πλήθος των γραμμάτων του αλφάβητου = πόσα bits χρειαζόμαστε για να αναπαραστήσουμε τα γράμματα του αλφαβήτου
- ✓ Ο αριθμός των δυνατών μηνυμάτων μήκους m , σε γλώσσα με απόλυτο ρυθμό A , είναι 2^{Am}
- ✓ Έστω 2^{Rm} ο αριθμός των μηνυμάτων μήκους m γραμμάτων που ανήκουν στην γλώσσα (**έγκυρα**).
- ✓ Η περίσσεια της γλώσσας ορίζεται ως η ποσότητα: $D=A-R$ (είναι περίσσεια σε bits)
- ✓ Λατινικό αλφάβητο
 - Το λατινικό αλφάβητο μεταφέρει **$\log 26=4,7$ bits/character**, άρα $A = 5$
 - Από μετρήσεις, η μέση ποσότητα πληροφορίας που μεταφέρεται ανά character (per-character entropy) σε κατανοήσιμο Αγγλικό κείμενο είναι 1.5 bits
 - Ο πλεονασμός σε Αγγλικό κείμενο είναι $5-1,5 = 3,5$ bits

■ Πλεονασμός – Περίσσεια Γλώσσας

- ✓ Είναι επιθυμητό η περίσσεια D μιας γλώσσας να είναι όσο το δυνατόν μικρότερη
- ✓ Αν είναι μικρή:
 - Έστω ότι ο αντίπαλος έχει στην κατοχή του το κρυπτοκείμενο
 - κατά την προσπάθεια αποκρυπτογράφησης του Oscar αυτό θα έχει μεγαλύτερη πιθανότητα να αντιστοιχίζεται σε πολλά έγκυρα απλά κείμενα.
- ✓ Αν η περίσσεια είναι μεγάλη
 - ο αντίπαλος θα μπορεί πιο εύκολα να αναγνωρίσει το ζητούμενο απλό κείμενο ή να αποκλείσει κλειδιά
 - τα λάθος κλειδιά θα αποκρυπτογραφούν το κρυπτοκείμενο σε μη έγκυρα κείμενα με μεγάλη πιθανότητα.
- ✓ Υπάρχει εξάρτηση μεταξύ της περιόδου της γλώσσας και του μεγέθους του κρυπτοκειμένου που χρειάζεται να έχει ο αντίπαλος για να ανακτήσει το απλό κείμενο

- Πλεονασμός – Περίσσεια Γλώσσας
- [Shannon 1949]:
- **unicity distance (UD)**= η μέση ποσότητα του κρυπτοκειμένου που χρειάζεται για την ανάκτηση του απλού κειμένου
= το μικρότερο μήκος του κρυπτοκειμένου με το οποίο $H(P/C)=0$.
- **Θεώρημα (Shannon): $UD = H(K) / D$**
 - όσο μικρότερη η περίσσεια της γλώσσας, τόσο περισσότερο κρυπτοκείμενο απαιτείται για να εντοπισθεί το κλειδί
- ✓ Παράδειγμα ενός permutation cipher με αντιμεταθέσεις μήκους t
 - Έστω ότι το plaintext έχει πλεονασμό των $D_{\Pi}=3,2$ bits/character
 - $H(K)/D_{\Pi} = \log(t!)/3,2$
 - Για $t=12$, χρειαζόμαστε τουλάχιστον 9 χαρακτήρες
 - Για $t=27$, χρειαζόμαστε τουλάχιστον 29 χαρακτήρες

- Μέχρι τώρα υποθέσαμε ότι ο Oscar γνωρίζει σε ποια γλώσσα έχει γραφτεί το plaintext
- Αν υποθέσουμε ότι δεν ξέρει τη γλώσσα?
 - ✓ Π.χ. Πολλές λατινογενείς γλώσσες έχουν το ίδιο αλφάβητο
- Έμφυτα χαρακτηριστικά γλώσσας που ένα ασφαλές κρυπτοσύστημα θα πρέπει να έχει την ικανότητα να αποκρύπτει
 - άνιση κατανομή συχνοτήτων των συμβόλων του απλού κειμένου,
 - περίσσεια μιας γλώσσας
- Έλεγχος Κάπα και έλεγχος Χι:
 - εκμεταλλεύονται στατιστικά χαρακτηριστικά κρυπτοκειμένου για να προσδιορίσουν τη γλώσσα γραφής απλού κειμένου

■ Έλεγχος Κάπα:

- ✓ μέτρηση σχετικής συχνότητας εμφάνισης ενός συμβόλου στην ίδια θέση σε διαφορετικά κείμενα
- ✓ Έστω $M=[m_1m_2\dots m_n]$ και $M'=[m'_1m'_2\dots m'_n]$ δυο διαφορετικά κείμενα κοινού μήκους n .
- ✓ Η ποσότητα Κάπα ή ποσότητα ταύτισης ορίζεται ως:

$$\kappa(M, M') = (1/n)\sum_i \delta(m_i, m'_i) \text{ όπου}$$

$$\delta(\alpha, \beta) = \begin{cases} 1 & \text{αν } \alpha=\beta \\ 0 & \text{αν } \alpha\neq\beta \end{cases}$$

- ✓ Με στατιστικές αναλύσεις έχει βρεθεί ότι η ποσότητα κ εξαρτάται από τη γλώσσα στην οποία είναι τα κείμενα M, M' και είναι διαφορετική για κάθε γλώσσα
- ✓ Για μονοαλφαβητικές αντικαταστάσεις και πολυαλφαβητικές γραμμικής φύσης (π.χ. Vigenere), η ποσότητα κ 2 κρυπτοκειμένων (με το ίδιο κλειδί) είναι στατιστικά ίση με την ποσότητα κ των 2 αντίστοιχων plaintexts

Γλώσσα	Πλήθος γραμμιάτων αλφάβητου	Κάπα (%)
Ελληνικά*	24	8,75
Αγγλικά	26	6,61
Γερμανικά	26	7,62
Γαλλικά	26	7,78
Ιταλικά	26	7,38
Ισπανικά	26	7,75
Ιαπωνικά (Romaji)	26	8,19
Ρώσικα	32	5,29

■ Έλεγχος Χι:

- ✓ Κρυπταναλυτικά πιο αδύναμος από τον έλεγχο Κάπα
- ✓ Μέτρηση συχνότητας εμφάνισης συμβόλου σε διαφορετικά κείμενα
- ✓ Έστω $M=[m_1m_2\dots m_n]$ και $M'=[m'_1m'_2\dots m'_n]$ δυο διαφορετικά κείμενα κοινού μήκους n και $\{x_1, x_2, \dots, x_m\}$ το αλφάβητο των κειμένων
- ✓ Έστω f_i και f'_i οι συχνότητες εμφάνισης του συμβόλου x_i στα κείμενα M και M' αντίστοιχα.
- ✓ Η ποσότητα χ ορίζεται ως:

$$\chi(M, M') = (1/n) \sum_i f_i * f'_i$$

- ✓ Με στατιστικές αναλύσεις έχει βρεθεί ότι η ποσότητα χ εξαρτάται από τη γλώσσα στην οποία είναι τα κείμενα M, M' και είναι διαφορετικό για κάθε γλώσσα
- ✓ Μόνο για μονοαλφαβητική αντικατάσταση