

ΠΑΝΕΠΙΣΤΗΜΙΟ ΠΕΛΟΠΟΝΝΗΣΟΥ

Κωδικοποίηση Πηγής

Θεωρία Πληροφορίας και Κωδίκων

Εαρινό Εξάμηνο

Τμήμα Πληροφορικής και Τηλεπικοινωνιών

Νικόλαος Χ. Σαγιάς

Καθηγητής

Webpage: <https://eclass.uop.gr/courses/DIT221/>

e-mail: nsagias@uop.gr

30/4/2020 1:44:40 μμ

Κωδικοποίηση Πηγής

- Ένας κωδικοποιητής πηγής δέχεται ως είσοδο σύμβολα από πηγή πληροφορίας και εξάγει bit



- Έστω πηγή συμβόλων $\mathcal{L} = \{s_1, s_2, \dots, s_n\}$ τα οποία έχουν ανεξάρτητες πιθανότητες $\{P_1, P_2, \dots, P_n\}$
- Τα bit εξόδου του κωδικοποιητή είναι οργανωμένα σε προκαθορισμένες ομάδες από bit (όχι κατ' ανάγκη ίδιου μήκους), οι οποίες ονομάζονται κωδικολέξεις (*codewords*)
- Για το σύμβολο s_i (με $i=1,2,\dots,n$), ο κωδικοποιητής παράγει την κωδικολέξη $c(s_i)$ μήκους ℓ_i σε bit

$$s_i \rightarrow c(s_i)$$

- Προφανώς, η πιθανότητα εμφάνισης του s_i θα είναι ίδια με την πιθανότητα εμφάνισης του $c(s_i)$

Κωδικοποίηση Πηγής

- Το μέσο μήκος των κωδικολέξεων σε bit είναι

$$\bar{L} = \sum_{i=1}^n P_i \ell_i$$

- Παράδειγμα: Πηγή παράγει τα σύμβολα {A, B, Γ}, με πιθανότητες {0.5, 0.25, 0.25}, τα οποία κωδικοποιούνται ως εξής

$$s_1 = A \rightarrow c(s_1) = 01$$

$$s_2 = B \rightarrow c(s_2) = 110$$

$$s_3 = \Gamma \rightarrow c(s_3) = 00$$



- Για την ακολουθία συμβόλων ΑΑΓΒΒΓ, ο κωδικοποιητής θα παράξει την εξής ακολουθία bit

01 01 00 110 110 00

- Το μέσο μήκος των κωδικολέξεων είναι $\bar{L} = 0.5 \times 2 + 0.25 \times 3 + 0.25 \times 2 = 2.25$ bit

Κωδικοποίηση Πηγής

- Οι φυσικές πηγές παράγουν σήματα τα οποία έχουν μεγάλη ποσότητα πλεονασμού (*redundancy*)
- Για αποδοτική μετάδοση των σημάτων θα πρέπει πρώτα να αφαιρεθεί ο πλεονασμός
- Η (μη απωλεστική) διαδικασία αφαίρεσης του πλεονασμού ονομάζεται συμπίεση (*compression*)



- Η εντροπία της πηγής θέτει το θεμελιώδες όριο για την αφαίρεση της πλεοναστικής πληροφορίας

Κωδικοποίηση Πηγής

- Ένα κώδικας ονομάζεται αντιστρέψιμος εφόσον κάθε σύμβολο της πηγής απεικονίζεται από μία διαφορετική ακολουθία από bit

$$s_i \neq s_j \Rightarrow c(s_i) \neq c(s_j)$$

- Το πρόβλημα των αντιστρέψιμων κωδίκων είναι ότι δεν είναι κατ' ανάγκη μονοσήμαντα αποκωδικοποιήσιμοι

- Παράδειγμα: Η ακολουθία 0 0 1 1 0 1 αποκωδικοποιείται ως

Γ Δ Α Β, Α Α Β Β Β Α Β, Γ Β Β Α Β ή Β Β Δ Α Β

Σύμβολα	Κωδικολέξεις
$s_1 = A$	$c(s_1) = 0$
$s_2 = B$	$c(s_2) = 1$
$s_3 = \Gamma$	$c(s_3) = 00$
$s_4 = \Delta$	$c(s_4) = 11$

Κωδικοποίηση Πηγής

- Υποσύνολο των αντιστρέψιμων κωδίκων είναι οι μονοσήμαντα αποκωδικοποιήσιμοι κώδικες

$$c(s_1 s_2 \cdots s_n) \rightarrow c(s_1) c(s_2) \cdots c(s_n) \rightarrow s_1 s_2 \cdots s_n$$

- Για την αποκωδικοποίηση των μονοσήμαντα αποκωδικοποιήσιμων κωδίκων πιθανόν να πρέπει να ληφθεί έως και όλη η ακολουθία των κωδικών λέξεων

- Οι μονοσήμαντα αποκωδικοποιήσιμοι κώδικες χαρακτηρίζονται από υψηλή πολυπλοκότητα κατά την αποκωδικοποίηση

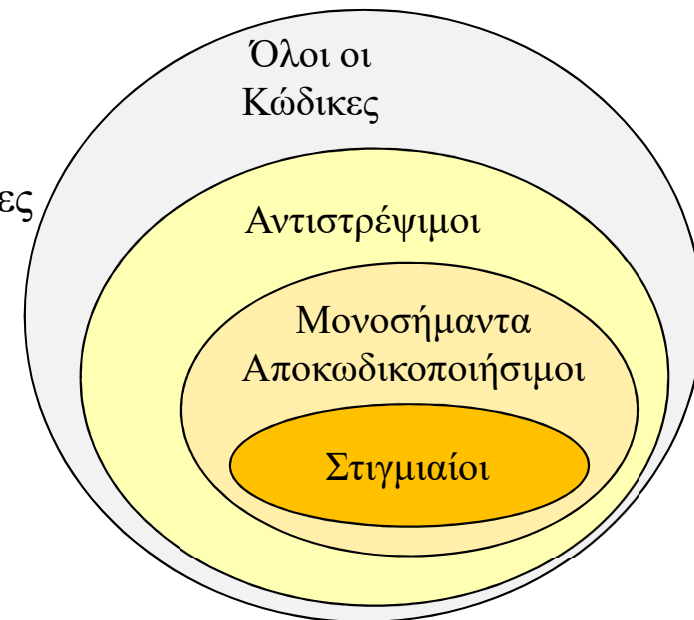
- Παράδειγμα: Η ακολουθία 1 1 0 0 0 1 0 0 0 μπορεί να αποκωδικοποιηθεί αρχικά ως Γ Β 0 1 0 0 0, όμως για το 0 που ακολουθεί δεν υπάρχει κατάλληλη κωδική λέξη.

Η ορθή αποκωδικοποίηση είναι Δ Β Α Β

Σύμβολα	Κωδικολέξεις
$s_1 = A$	$c(s_1) = 10$
$s_2 = B$	$c(s_2) = 00$
$s_3 = \Gamma$	$c(s_3) = 11$
$s_4 = \Delta$	$c(s_4) = 110$

Κωδικοποίηση Πηγής

- Υποσύνολο των μονοσήμαντα αποκωδικοποιήσιμων κωδίκων είναι οι στιγμιαίοι (*instantaneous*) ή απροθεματικοί (*prefix*) κώδικες
- Οι στιγμιαίοι κώδικες χαρακτηρίζονται από το γεγονός ότι καμία κωδική λέξη δεν αποτελεί πρόθεμα κάποιας άλλης
- Οι κωδικές λέξεις ενός στιγμιαίου κώδικα μπορούν να αποκωδικοποιηθούν άμεσα μόλις ληφθούν, χωρίς πχ να απαιτείται να ληφθούν επόμενες λέξεις
- Παράδειγμα: Η ακολουθία 1 1 1 0 0 0 1 0 0 0 αποκωδικοποιείται μοναδικά ως Δ A A A B A A



Σύμβολα	Κωδικολέξεις
$s_1 = A$	$c(s_1) = 0$
$s_2 = B$	$c(s_2) = 10$
$s_3 = \Gamma$	$c(s_3) = 110$
$s_4 = \Delta$	$c(s_4) = 111$

Κωδικοποίηση Πηγής

- Η πηγή παράγει σύμβολα $\mathcal{L} = \{s_1, s_2, \dots, s_n\}$ με ανεξάρτητες πιθανότητες $\{P_1, P_2, \dots, P_n\}$
- Για το σύμβολο s_i ο κωδικοποιητής παράγει την κωδική λέξη $c(s_i)$ μήκους ℓ_i σε bit (με $i = 1, 2, \dots, n$)

- Αν ο κώδικας είναι στιγμιαίος, ικανοποιεί την ανισότητα Kraft-McMillan

$$\sum_{i=1}^n 2^{-\ell_i} \leq 1$$

- Οι μονοσήμαντα αποκωδικοποιήσιμοι κώδικες ικανοποιούν επίσης την παραπάνω ανισότητα και άρα, αν ένας κώδικας ικανοποιεί την ανισότητα Kraft-McMillan δεν είναι κατ' ανάγκη στιγμιαίος

Κωδικολέξεις			
$\ell = 1$	$\ell = 2$	$\ell = 3$	$\ell = 3$
0	00	000	0000
			0001
		001	0010
			0011
	01	010	0100
			0101
011		0110	
		0111	
1	10	100	100
			1001
		101	1010
			1011
	11	110	1100
			1101
111		1110	
		1111	

Κωδικοποίηση Πηγής

- Ο κώδικας I δεν είναι στιγμιαίος, διότι δεν επαληθεύει την ανισότητα

$$\sum_{i=1}^4 2^{-l_i} = 2^{-1} + 2^{-1} + 2^{-2} + 2^{-2} = 1.5 > 1$$

- Οι κώδικες II και III ικανοποιούν την ανισότητα Kraft-McMillan

$$\sum_{i=1}^4 2^{-l_i} = 2^{-1} + 2^{-2} + 2^{-3} + 2^{-3} = 1$$

- Ωστόσο, μόνο ο κώδικας II είναι στιγμιαίος, ενώ ο III είναι μονοσήμαντα αποκωδικοποιήσιμος

Σύμβολο	Πιθανότητα	Κώδικας I	Κώδικας II	Κώδικας III
s_1	0.5	0	0	0
s_2	0.25	1	10	01
s_3	0.125	00	110	011
s_4	0.125	11	111	0111

Κωδικολέξεις				
$\ell = 1$	$\ell = 2$	$\ell = 3$	$\ell = 3$	
0	00	000	0000	
			0001	
		001	0010	
			0011	
	01		010	0100
				0101
		011	0110	
			0111	
1	10		100	
			1001	
		101	1010	
			1011	
	11		110	1100
				1101
		111	1110	
			1111	

Κωδικοποίηση Πηγής

- Το ελάχιστο μέσο μήκος των κωδικών λέξεων μιας πηγής δίδεται μέσω του [1^ο θεωρήματος κωδικοποίησης του Shannon](#)

- Για μία διακριτή πηγή χωρίς μνήμη εντροπίας $H(\mathcal{L})$, το μέσο μήκος \bar{L} των κωδικών λέξεων οποιουδήποτε σχήματος κωδικοποίησης δεν μπορεί να είναι μικρότερο από $H(\mathcal{L})$

$$\bar{L} \geq H(\mathcal{L})$$

- Σε περίπτωση που χρησιμοποιηθεί σχήμα κωδικοποίησης, όπου δεν ικανοποιείται η παραπάνω συνθήκη, τα σύμβολα κατά την αποκωδικοποίηση θα είναι διαφορετικά σε σχέση με τα αρχικά

- Η απόδοση ενός κωδικοποιητή πηγής ορίζεται ως

$$\eta = \frac{H(\mathcal{L})}{\bar{L}}$$

Κωδικοποίηση Πηγής

- Για διακριτή πηγή χωρίς μνήμη εντροπίας $H(\mathcal{L})$, ποιο είναι το ελάχιστο μέσο μήκος κωδικολέξεων ενός στιγμιαίου κώδικα που μπορεί να κατασκευαστεί;

$$\bar{L} = \sum_{i=1}^n P_i \ell_i \xrightarrow{\bar{\ell}_1, \bar{\ell}_2, \dots, \bar{\ell}_n} L_{\min}$$

- Ουσιαστικά πρόκειται για το εξής πρόβλημα βελτιστοποίησης:

$$\min_{\hat{\ell}_1, \hat{\ell}_2, \dots, \hat{\ell}_n} \left\{ \sum_{i=1}^n P_i \ell_i \right\}$$

$$\text{Υπό Συνθήκη: } \sum_{i=1}^n 2^{-\ell_i} \leq 1$$

- Το παραπάνω πρόβλημα αντιμετωπίζεται χρησιμοποιώντας πολλαπλασιαστές Lagrange

Κωδικοποίηση Πηγής

- Θα ελαχιστοποιήσουμε την ποσότητα

$$J = \sum_{i=1}^n P_i \ell_i + \lambda \sum_{i=1}^n 2^{-\ell_i}$$

- Παραγωγίζοντας ως προς ℓ_i και εξισώνοντας με το μηδέν (με $i = 1, 2, \dots, n$) έχουμε

$$\left. \frac{\partial J}{\partial \ell_i} \right|_{\hat{\ell}_i} = 0 \Leftrightarrow P_i - \lambda 2^{-\hat{\ell}_i} \ln(2) = 0 \Leftrightarrow 2^{-\hat{\ell}_i} = \frac{P_i}{\lambda \ln(2)}$$

- Με αντικατάσταση στον υπό συνθήκη περιορισμό (συγκεκριμένα στην ισότητα), προκύπτει το λ

$$\sum_{i=1}^n 2^{-\hat{\ell}_i} = 1 \Leftrightarrow \sum_{i=1}^n \frac{P_i}{\lambda \ln(2)} = 1 \Leftrightarrow \lambda = \frac{1}{\ln(2)}$$

- Συνεπώς,

$$P_i = 2^{-\hat{\ell}_i}$$

Κωδικοποίηση Πηγής

- Άρα, το βέλτιστο μήκος της i -ωστής κωδικολέξης $c(s_i)$ είναι ακριβώς η ποσότητα πληροφορίας του αντίστοιχου συμβόλου s_i , δηλαδή

$$\hat{\ell}_i = -\log_2(P_i)$$

- Συνεπώς, το μέσο μήκος των κωδικολέξεων (σε bit) είναι

$$\bar{L}_{\min} = \sum_{i=1}^n P_i \hat{\ell}_i = -\sum_{i=1}^n P_i \log_2(P_i) = H(\mathcal{L})$$

- Για να είναι το μήκος κάθε κωδικής λέξης ακέραιος, θα πρέπει σε όλες η κατανομή των πιθανοτήτων να είναι της μορφής $P_i \sim 2^{-k}$, με k κάποιο θετικό ακέραιο

Κωδικοποίηση Πηγής

- Στην πράξη οι πιθανότητες εμφάνισης των συμβόλων της πηγής δεν είναι κατ' ανάγκη της μορφής $P_i \sim 2^{-k}$, και συνεπώς, το μέσο μήκος των κωδικολέξεων είναι μεγαλύτερο από την εντροπία
- Για δεδομένη διακριτή πηγή χωρίς μνήμη κατανομής \mathbf{P} και εντροπίας $H(\mathcal{L})$, μπορεί να κατασκευαστεί βέλτιστος κώδικας με μέσο μήκος κωδικολέξεων

$$H(\mathcal{L}) \leq \bar{L} < H(\mathcal{L}) + 1$$

- Δηλαδή, το μέσο μήκος των κωδικολέξεων μπορεί να είναι έως 1 bit άνω του ελάχιστου δυνατού

Κωδικοποίηση Πηγής

- Προκειμένου να επιτύχουμε μέσο μήκος κωδικολέξεων πολύ κοντά στην εντροπία, βάσει των n συμβόλων της πηγής, σχηματίζουμε υπερσύμβολα μπλοκ \mathcal{L}^N μήκους N συμβόλων

- Με $\mathbb{E}\langle \ell(s_1, s_2, \dots, s_N) \rangle$ συμβολίζουμε το μέσο μήκος των κωδικολέξεων ανά υπερσύμβολο

- Για το νέο κώδικα το μέσο μήκος κωδικολέξεων ανά σύμβολο πηγής θα είναι

$$\bar{L}_N = \frac{1}{N} \mathbb{E} \langle \ell(s_1, s_2, \dots, s_N) \rangle = \frac{1}{N} \sum_{s \in \mathcal{L}^N} p(s_1, s_2, \dots, s_N) \ell(s_1, s_2, \dots, s_N)$$

- Βάσει προηγούμενης ανισότητας μπορεί να κατασκευαστεί κώδικας μέσου μήκους κωδικολέξεων

$$H(\mathcal{L}^N) \leq \mathbb{E} \langle \ell(s_1, s_2, \dots, s_N) \rangle < H(\mathcal{L}^N) + 1$$

Κωδικοποίηση Πηγής

- Όπως έχουμε δει, για στατιστικά ανεξάρτητα σύμβολα πηγής ισχύει $H(\mathcal{L}^N) = N H(\mathcal{L})$ και άρα

$$N H(\mathcal{L}) \leq \mathbb{E} \langle \ell(s_1, s_2, \dots, s_n) \rangle < N H(\mathcal{L}) + 1 \Leftrightarrow$$

$$H(\mathcal{L}) \leq \bar{L}_N < H(\mathcal{L}) + \frac{1}{N}$$

- Επιλέγοντας μακροσκελείς ακολουθίες συμβόλων $N \rightarrow \infty$, επιτυγχάνουμε

$$\lim_{N \rightarrow \infty} \bar{L}_N = H(\mathcal{L})$$

- Δηλαδή, όταν οι πιθανότητες εμφάνισης των συμβόλων της πηγής δεν είναι της μορφής $P_i \sim 2^{-k}$, μπορούμε να σχηματίσουμε υπερσύμβολα μπλοκ μήκους N συμβόλων και τότε, το μέσο μήκος των κωδικολέξεων ανά σύμβολο θα βρίσκεται πολύ κοντά στην εντροπία της πηγής
- Επιπλέον, το παραπάνω συμπέρασμα ισχύει και για πηγή με στατιστικά εξαρτημένα σύμβολα

Κωδικοποίηση Πηγής

Κωδικοποίηση Shannon

- Διατάσσουμε τα σύμβολα s_1, s_2, \dots, s_n κατά φθίνουσα πιθανότητα $P_1 \geq P_2 \geq \dots \geq P_n$
- Αντιστοιχίζουμε την παράμετρο F_i στο σύμβολο s_i (με $i = 1, 2, \dots, n$), ξεκινώντας με $F_1 = 0$ και
$$F_i = \sum_{k=1}^{i-1} P_k$$
- Το μήκος της κωδικολέξης του s_i είναι ένας θετικός ακέραιος l_i που φράσσεται από την ανισότητα
$$-\log_2(P_i) \leq l_i < 1 - \log_2(P_i)$$
- Η κωδική λέξη για το σύμβολο s_i προκύπτει από τα πρώτα l_i υψηλότερης σημαντικότητας ψηφία (MSB) του κλασματικού μέρους του F_i , αφού πρώτα έχει αυτό μετατραπεί στο 2αδικό σύστημα

Κωδικοποίηση Πηγής

- Ο κώδικας Shannon είναι μεταβλητού μήκους και υποβέλτιστος ως προς το μέσο μήκος των κωδικολέξεων

- Το μέσο μήκος των κωδικολέξεων είναι

$$H(\mathcal{L}) \leq \bar{L} < H(\mathcal{L}) + 1$$

- Ο κώδικας που παράγεται είναι στιγμιαίος
- Βάσει της $-\log_2(P_i) \leq l_i < 1 - \log_2(P_i)$, σπάνια μηνύματα κωδικοποιούνται με μεγάλο μήκος
- Κάθε κωδική λέξη διαφέρει από τις υπόλοιπες σε ένα ή περισσότερα ψηφία

Κωδικοποίηση Πηγής

- Παράδειγμα: Διακριτή πηγή χωρίς μνήμη παράγει ανεξάρτητα σύμβολα με πιθανότητες $\{0.2, 0.1, 0.2, 0.4, 0.1\}$
- Να βρεθεί η εντροπία της πηγής και κωδικοποιηθούν τα σύμβολα κατά Shannon, όπου να βρεθεί το μέσο μήκος των bit ανά σύμβολο

- Η εντροπία της διακριτής πηγής είναι

$$\begin{aligned} H(\mathcal{L}) &= \sum_{i=1}^5 P_i \log_2 \left(\frac{1}{P_i} \right) = \\ &= 0.2 \log_2 \left(\frac{1}{0.2} \right) + 0.1 \log_2 \left(\frac{1}{0.1} \right) + 0.2 \log_2 \left(\frac{1}{0.2} \right) + 0.4 \log_2 \left(\frac{1}{0.4} \right) + 0.1 \log_2 \left(\frac{1}{0.1} \right) \text{ bit} = \\ &= 2.12193 \text{ bit} \end{aligned}$$

Κωδικοποίηση Πηγής

- Παράδειγμα (συνέχεια):

Κωδικοποίηση Shannon						
a/a i	Σύμβολο s_i	Πιθανότητα P_i	MSB Ψηφία l_i	10αδικό $(F_i)_{10}$	2αδικό $(F_i)_2$	Κωδική Λέξη $c(s_i)$
1	s_1	0.4	2	0.0	0.0000	0 0
2	s_2	0.2				
3	s_3	0.2				
4	s_4	0.1				
5	s_5	0.1				

- Σύμβολο s_1 με πιθανότητα εμφάνισης $P_1 = 0.4$

- Μήκος κωδικολέξης: $-\log_2(P_1) \leq l_1 \leq 1 - \log_2(P_1) \Leftrightarrow 1.32 \leq l_1 \leq 2.32 \rightarrow l_1 = 2$

- Αναπαράσταση του $F_1 = (0.0)_{10}$ στο 2αδικό $F_1 = (0.0000)_2$

- $l_1 = 2$ MSB του κλασματικού μέρους: 0000

- Κωδική λέξη: $c(s_1) = 0 \ 0$

Μετατροπή F_1 στο 2αδικό

$$\begin{aligned}
 0 \times 2 &= \boxed{0} + 0 \\
 0 \times 2 &= \boxed{0} + 0 \\
 0 \times 2 &= \boxed{0} + 0 \\
 0 \times 2 &= \boxed{0} + 0
 \end{aligned}$$

Κωδικοποίηση Πηγής

- Παράδειγμα (συνέχεια):

Κωδικοποίηση Shannon						
a/a i	Σύμβολο s_i	Πιθανότητα P_i	MSB Ψηφία l_i	10αδικό $(F_i)_{10}$	2αδικό $(F_i)_2$	Κωδική Λέξη $c(s_i)$
1	s_1	0.4	2	0.0	0.0000	0 0
2	s_2	0.2	3	0.4	0.0110	0 1 1
3	s_3	0.2				
4	s_4	0.1				
5	s_5	0.1				

- Σύμβολο s_2 με πιθανότητα εμφάνισης $P_2 = 0.2$

- Μήκος κωδικολέξης: $-\log_2(P_2) \leq l_2 \leq 1 - \log_2(P_2) \Leftrightarrow 2.32 \leq l_2 \leq 3.32 \rightarrow l_2 = 3$
- Αναπαράσταση του $F_2 = F_1 + P_1 = (0.4)_{10}$ στο 2αδικό $F_2 = (0.0110)_2$
- $l_2 = 3$ MSB του κλασματικού μέρους: 0110
- Κωδική λέξη: $c(s_2) = 0 \ 1 \ 1$

Μετατροπή F_2 στο 2αδικό

$$\begin{aligned}
 0.4 \times 2 &= \boxed{0} + 0.8 \\
 0.8 \times 2 &= \boxed{1} + 0.6 \\
 0.6 \times 2 &= \boxed{1} + 0.2 \\
 0.2 \times 2 &= \boxed{0} + 0.4
 \end{aligned}$$

Κωδικοποίηση Πηγής

- Παράδειγμα (συνέχεια):

Κωδικοποίηση Shannon						
a/a i	Σύμβολο s_i	Πιθανότητα P_i	MSB Ψηφία l_i	10αδικό $(F_i)_{10}$	2αδικό $(F_i)_2$	Κωδική Λέξη $c(s_i)$
1	s_1	0.4	2	0.0	0.0000	0 0
2	s_2	0.2	3	0.4	0.0110	0 1 1
3	s_3	0.2	3	0.6	0.1001	1 0 0
4	s_4	0.1				
5	s_5	0.1				

- Σύμβολο s_3 με πιθανότητα εμφάνισης $P_3 = 0.2$

- Μήκος κωδικολέξης: $-\log_2(P_3) \leq l_3 \leq 1 - \log_2(P_3) \Leftrightarrow 2.32 \leq l_3 \leq 3.32 \rightarrow l_3 = 3$
- Αναπαράσταση του $F_3 = F_2 + P_2 = (0.6)_{10}$ στο 2αδικό $F_3 = (0.1001)_2$
- $l_3 = 3$ MSB του κλασματικού μέρους: 1001
- Κωδική λέξη: $c(s_3) = 1 \ 0 \ 0$

Μετατροπή F_3 στο 2αδικό

$$\begin{aligned}
 0.6 \times 2 &= \boxed{1} + 0.2 \\
 0.2 \times 2 &= \boxed{0} + 0.4 \\
 0.4 \times 2 &= \boxed{0} + 0.8 \\
 0.8 \times 2 &= \boxed{1} + 0.6
 \end{aligned}$$

Κωδικοποίηση Πηγής

- Παράδειγμα (συνέχεια): Τα πηγαία σύμβολα αναδιατάσσονται κατά φθίνουσα πιθανότητα

Κωδικοποίηση Shannon						
a/a i	Σύμβολο s_i	Πιθανότητα P_i	MSB Ψηφία l_i	10αδικό $(F_i)_{10}$	2αδικό $(F_i)_2$	Κωδική Λέξη $c(s_i)$
1	s_1	0.4	2	0.0	0.0000	0 0
2	s_2	0.2	3	0.4	0.0110	0 1 1
3	s_3	0.2	3	0.6	0.1001	1 0 0
4	s_4	0.1	4	0.8	0.11001	1 1 0 0
5	s_5	0.1				

- Σύμβολο s_4 με πιθανότητα εμφάνισης $P_4 = 0.1$
 - Μήκος κωδικολέξης: $-\log_2(P_4) \leq l_4 \leq 1 - \log_2(P_4) \Leftrightarrow 3.32 \leq l_4 \leq 4.32 \rightarrow l_4 = 4$
 - Αναπαράσταση του $F_4 = F_3 + P_3 = (0.8)_{10}$ στο 2αδικό $F_4 = (0.11001)_2$
 - $l_4 = 4$ MSB του κλασματικού μέρους: **11001**
 - Κωδική λέξη: $c(s_4) = 1 \ 1 \ 0 \ 0$

Μετατροπή F_4 στο 2αδικό

$$\begin{aligned}
 0.8 \times 2 &= \mathbf{1} + 0.6 \\
 0.6 \times 2 &= \mathbf{1} + 0.2 \\
 0.2 \times 2 &= \mathbf{0} + 0.4 \\
 0.4 \times 2 &= \mathbf{0} + 0.8 \\
 0.8 \times 2 &= \mathbf{1} + 0.6
 \end{aligned}$$

Κωδικοποίηση Πηγής

- Παράδειγμα (συνέχεια):

Κωδικοποίηση Shannon						
a/a i	Σύμβολο s_i	Πιθανότητα P_i	MSB Ψηφία l_i	10αδικό $(F_i)_{10}$	2αδικό $(F_i)_2$	Κωδική Λέξη $c(s_i)$
1	s_1	0.4	2	0.0	0.0000	0 0
2	s_2	0.2	3	0.4	0.0110	0 1 1
3	s_3	0.2	3	0.6	0.1001	1 0 0
4	s_4	0.1	4	0.8	0.11001	1 1 0 0
5	s_5	0.1	4	0.9	0.11100	1 1 1 0

- Σύμβολο s_5 με πιθανότητα εμφάνισης $P_5 = 0.1$

- Μήκος κωδικολέξης: $-\log_2(P_5) \leq l_5 \leq 1 - \log_2(P_5) \Leftrightarrow 3.32 \leq l_4 \leq 4.32 \rightarrow l_5 = 4$
- Αναπαράσταση του $F_5 = F_4 + P_4 = (0.9)_{10}$ στο 2αδικό $F_5 = (0.11100)_2$
- $l_5 = 4$ MSB του κλασματικού μέρους: **11100**
- Κωδική λέξη: $c(s_5) = 1 \ 1 \ 1 \ 0$

Μετατροπή F_5 στο 2αδικό

$$\begin{aligned}
 0.9 \times 2 &= \mathbf{1} + 0.8 \\
 0.8 \times 2 &= \mathbf{1} + 0.6 \\
 0.6 \times 2 &= \mathbf{1} + 0.2 \\
 0.2 \times 2 &= \mathbf{0} + 0.4 \\
 0.4 \times 2 &= \mathbf{0} + 0.8
 \end{aligned}$$

Κωδικοποίηση Πηγής

- Παράδειγμα (συνέχεια):

Κωδικοποίηση Shannon						
a/a i	Σύμβολο s_i	Πιθανότητα P_i	MSB Ψηφία ℓ_i	10αδικό $(F_i)_{10}$	2αδικό $(F_i)_2$	Κωδική Λέξη $c(s_i)$
1	s_1	0.4	2	0.0	0.0000	0 0
2	s_2	0.2	3	0.4	0.0110	0 1 1
3	s_3	0.2	3	0.6	0.1001	1 0 0
4	s_4	0.1	4	0.8	0.1100	1 1 0 0
5	s_5	0.1	4	0.9	0.1110	1 1 1 0

- Το μέσο μήκος των κωδικολέξεων του κώδικά Shannon είναι

$$\bar{L} = \sum_{i=1}^5 P_i \ell_i = 0.4 \times 2 + 0.2 \times 3 + 0.2 \times 4 + 0.1 \times 4 + 0.1 \times 4 = 2.8 \text{ bit}$$

- Η απόδοση του κώδικα είναι

$$\eta = \frac{H(\mathcal{L})}{\bar{L}} = \frac{2.12}{2.8} \approx 75.8\%$$

- Το μέσο μήκος των κωδικολέξεων είναι περίπου κατά 0.68 bit μεγαλύτερο από βέλτιστο κώδικα

Κωδικοποίηση Πηγής

Κωδικοποίηση Fano

- Διατάσσουμε τα σύμβολα s_1, s_2, \dots, s_n κατά φθίνουσα πιθανότητα $P_1 \geq P_2 \geq \dots \geq P_n$
- Διαχωρίζουμε τη λίστα σε 2 ομάδες με κοντινές τιμές πιθανότητας αθροιστικά ανά ομάδα
- Στην άνω ομάδα τοποθετούμε το 0 και στην κάτω το 1
- Επαναλαμβάνουμε την παραπάνω διαδικασία για τις νέες υποομάδες που δημιουργούνται
- Η διαδικασία σταματά όταν δεν υπάρχουν άλλες υποομάδες προς διαίρεση
- Διατρέχουμε τα bit από την αρχή προς το τέλος για να σχηματιστούν οι κωδικολέξεις

Κωδικοποίηση Πηγής

- Ο κώδικας Fano είναι μεταβλητού μήκους και υποβέλτιστος ως προς το μέσο μήκος των κωδικολέξεων

- Το μέσο μήκος των κωδικολέξεων είναι

$$H(\mathcal{L}) \leq \bar{L} < H(\mathcal{L}) + 1$$

- Ο κώδικας που παράγεται είναι στιγμιαίος
- Σπάνια μηνύματα κωδικοποιούνται με μεγάλο μήκος
- Κάθε κωδική λέξη διαφέρει από τις υπόλοιπες σε ένα ή περισσότερα ψηφία

Κωδικοποίηση Πηγής

- Παράδειγμα (συνέχεια): Τα πηγαία σύμβολα αναδιατάσσονται κατά φθίνουσα πιθανότητα
 - ❑ Διαχωρίζουμε τη λίστα σε 2 ομάδες με κοντινές τιμές αθροιστικής πιθανότητας ανά ομάδα
 - ❑ Στην άνω ομάδα τοποθετούμε το 0 και στην κάτω το 1
 - ❑ Επαναλαμβάνουμε την παραπάνω διαδικασία για τις νέες υποομάδες που δημιουργούνται

Κωδικοποίηση Fano			
a/a i	Σύμβολο s_i	Πιθανότητα P_i	1 ^η Διαίρεση
1	s_1	0.4	0.4
2	s_2	0.2	0.2
3	s_3	0.2	0.2
4	s_4	0.1	0.1
5	s_5	0.1	0.1

Κωδικοποίηση Πηγής

● Παράδειγμα (συνέχεια):

- ❑ Διαχωρίζουμε τη λίστα σε 2 ομάδες με κοντινές τιμές πιθανότητας αθροιστικά ανά ομάδα
- ❑ Στην άνω ομάδα τοποθετούμε το 0 και στην κάτω το 1
- ❑ Επαναλαμβάνουμε την παραπάνω διαδικασία για τις νέες υποομάδες που δημιουργούνται

Κωδικοποίηση Fano				
a/a i	Σύμβολο s_i	Πιθανότητα P_i	1 ^η Διαίρεση	2 ^η Διαίρεση
1	s_1	0.4	0.4	0.4
2	s_2	0.2	0.2	0.2
3	s_3	0.2	0.2	0.2
4	s_4	0.1	0.1	0.1
5	s_5	0.1	0.1	0.1

Κωδικοποίηση Fano: Η διαδικασία διαχωρίζει τα σύμβολα σε ομάδες με κοντινές πιθανότητες. Στην άνω ομάδα (0) περιλαμβάνονται τα σύμβολα s_1, s_2, s_3 και στην κάτω ομάδα (1) τα s_4, s_5 . Η διαδικασία επαναλαμβάνεται για τις υποομάδες.

Κωδικοποίηση Πηγής

● Παράδειγμα (συνέχεια):

- ❑ Διαχωρίζουμε τη λίστα σε 2 ομάδες με κοντινές τιμές πιθανότητας αθροιστικά ανά ομάδα
- ❑ Στην άνω ομάδα τοποθετούμε το 0 και στην κάτω το 1
- ❑ Η διαδικασία σταματά όταν δεν υπάρχουν άλλες υποομάδες προς διαίρεση

Κωδικοποίηση Fano					
a/a i	Σύμβολο s_i	Πιθανότητα P_i	1 ^η Διαίρεση	2 ^η Διαίρεση	3 ^η Διαίρεση
1	s_1	0.4	0.4	0.4	
2	s_2	0.2	0.2	0.2	
3	s_3	0.2	0.2	0.2	
4	s_4	0.1	0.1	0.1	0.1
5	s_5	0.1	0.1	0.1	0.1

Κωδικοποίηση Πηγής

- Παράδειγμα (συνέχεια):

- Το μέσο μήκος των κωδικολέξεων του κώδικά Shannon είναι

$$\bar{L} = \sum_{i=1}^5 P_i \ell_i = 0.4 \times 2 + 0.2 \times 2 + 0.2 \times 2 + 0.1 \times 3 + 0.1 \times 3 = 2.2 \text{ bit}$$

- Η απόδοση του κώδικα είναι

$$\eta = \frac{H(\mathcal{L})}{\bar{L}} = \frac{2.12}{2.2} \approx 96.4\%$$

- Το μέσο μήκος των κωδικολέξεων διαφέρει λιγότερο από 0.1 bit από την εντροπία της πηγής

Κωδικοποίηση Fano							
a/a i	Σύμβολο s _i	Πιθανότητα P _i	1 ^η Διαίρεση	2 ^η Διαίρεση	3 ^η Διαίρεση	Κωδικολέξη c(s _i)	Μήκος Κωδικολέξης l _i
1	s ₁	0.4	0.4 } 0	0.4 } 0		0 0	2
2	s ₂	0.2	0.2 } 0	0.2 } 1		0 1	2
3	s ₃	0.2	0.2 } 1	0.2 } 0		1 0	2
4	s ₄	0.1	0.1 } 1	0.1 } 1	0.1 } 0	1 1 0	3
5	s ₅	0.1	0.1 } 1	0.1 } 1	0.1 } 1	1 1 1	3

Κωδικοποίηση Πηγής

Κωδικοποίηση Huffman

- Διατάσσουμε τα σύμβολα s_1, s_2, \dots, s_n κατά φθίνουσα πιθανότητα $P_1 \geq P_2 \geq \dots \geq P_n$
- Στα 2 χαμηλότερης πιθανότητας σύμβολα αντιστοιχούμε το 0 και 1
- Τα 2 χαμηλότερης πιθανότητας σύμβολα συνδυάζονται σε ένα νέο με πιθανότητα το άθροισμα των πιθανοτήτων και ταξινομείται στην κατάλληλη θέση της λίστας
- Η παραπάνω διαδικασία επαναλαμβάνεται έως να μείνουν μόνο 2 νούμερα στη λίστα, στα οποία αντιστοιχούμε το 0 και 1
- Τέλος, διατρέχουμε από το τέλος προς την αρχή για να βρούμε την κωδικολέξη κάθε συμβόλου

Κωδικοποίηση Πηγής

- Ο κώδικας Huffman είναι μεταβλητού μήκους και βέλτιστος ως προς το μέσο μήκος των κωδικολέξεων

- Το μέσο μήκος των κωδικολέξεων είναι

$$H(\mathcal{L}) \leq \bar{L} < H(\mathcal{L}) + 1$$

- Ο κώδικας που παράγεται είναι στιγμιαίος

Κωδικοποίηση Πηγής

- Παράδειγμα: Διακριτή πηγή χωρίς μνήμη παράγει ανεξάρτητα σύμβολα με πιθανότητες $\{0.2, 0.1, 0.2, 0.4, 0.1\}$
- Να βρεθεί η εντροπία της πηγής και κωδικοποιηθούν τα σύμβολα κατά Huffman, όπου να βρεθεί το μέσο μήκος των bit ανά σύμβολο

Κωδικοποίηση Huffman						
a/a i	Σύμβολο s_i	Πιθανότητα P_i				
1	s_1	0.4				
2	s_2	0.2				
3	s_3	0.2				
4	s_4	0.1				
5	s_5	0.1				

Κωδικοποίηση Πηγής

- Παράδειγμα (συνέχεια):
 - Τα 2 χαμηλότερης πιθανότητας σύμβολα συνδυάζονται σε ένα νέο με πιθανότητα το άθροισμα των πιθανοτήτων και ταξινομείται στην κατάλληλη θέση της λίστας
 - Η παραπάνω διαδικασία επαναλαμβάνεται έως να μείνουν μόνο 2 νούμερα στη λίστα, στα οποία αντιστοιχούμε το 0 και 1

Κωδικοποίηση Huffman						
a/a <i>i</i>	Σύμβολο <i>s_i</i>	Πιθανότητα <i>P_i</i>	1 ^η Αναδιάταξη			
1	<i>s₁</i>	0.4	0.4			
2	<i>s₂</i>	0.2	0.2			
3	<i>s₃</i>	0.2	0.2			
4	<i>s₄</i>	0.1	0.2			
5	<i>s₅</i>	0.1				

(Η τοποθέτηση των νέων πιθανοτήτων τοποθετείται στην κορυφή της λίστας μεταξύ των συμβόλων ίσης πιθανότητας)

Κωδικοποίηση Πηγής

- Παράδειγμα (συνέχεια):
 - Τα 2 χαμηλότερης πιθανότητας σύμβολα συνδυάζονται σε ένα νέο με πιθανότητα το άθροισμα των πιθανοτήτων και ταξινομείται στην κατάλληλη θέση της λίστας
 - Η παραπάνω διαδικασία επαναλαμβάνεται έως να μείνουν μόνο 2 νούμερα στη λίστα, στα οποία αντιστοιχούμε το 0 και 1

Κωδικοποίηση Huffman						
a/a i	Σύμβολο s_i	Πιθανότητα P_i	1 ^η Αναδιάταξη	2 ^η Αναδιάταξη		
1	s_1	0.4	0.4	0.4		
2	s_2	0.2	0.2	0.4		
3	s_3	0.2	0.2	0.2		
4	s_4	0.1	0.2			
5	s_5	0.1				

(Η τοποθέτηση των νέων πιθανοτήτων τοποθετείται στην κορυφή της λίστας μεταξύ των συμβόλων ίσης πιθανότητας)

Κωδικοποίηση Πηγής

- Παράδειγμα (συνέχεια):
 - Τα 2 χαμηλότερης πιθανότητας σύμβολα συνδυάζονται σε ένα νέο με πιθανότητα το άθροισμα των πιθανοτήτων και ταξινομείται στην κατάλληλη θέση της λίστας
 - Η παραπάνω διαδικασία επαναλαμβάνεται έως να μείνουν μόνο 2 νούμερα στη λίστα

Κωδικοποίηση Huffman						
a/a i	Σύμβολο s_i	Πιθανότητα P_i	1 ^η Αναδιάταξη	2 ^η Αναδιάταξη	3 ^η Αναδιάταξη	
1	s_1	0.4	0.4	0.4	0.6	
2	s_2	0.2	0.2	0.4	0.4	
3	s_3	0.2	0.2	0.2		
4	s_4	0.1	0.2			
5	s_5	0.1				

Κωδικοποίηση Πηγής

- Παράδειγμα (συνέχεια):

- Τέλος, διατρέχουμε από το τέλος προς την αρχή για να βρούμε την κωδικολέξη κάθε συμβόλου

Κωδικοποίηση Huffman						
a/a i	Σύμβολο s_i	Πιθανότητα P_i	1 ^η Αναδιάταξη	2 ^η Αναδιάταξη	3 ^η Αναδιάταξη	Κωδική Λέξη $c(s_i)$
1	s_1	0.4	0.4	0.4	0.6	0
2	s_2	0.2	0.2	0.4	0.4	
3	s_3	0.2	0.2	0.2		1
4	s_4	0.1	0.2			
5	s_5	0.1				

Κωδικοποίηση Πηγής

- Παράδειγμα (συνέχεια):

- Τέλος, διατρέχουμε από το τέλος προς την αρχή για να βρούμε την κωδικολέξη κάθε συμβόλου

Κωδικοποίηση Huffman						
α/α i	Σύμβολο s_i	Πιθανότητα P_i	1 ^η Αναδιάταξη	2 ^η Αναδιάταξη	3 ^η Αναδιάταξη	Κωδική Λέξη $c(s_i)$
1	s_1	0.4	0.4	0.4	0.6 } 0	0 0
2	s_2	0.2	0.2	0.4 } 0	0.4 } 1	1 0
3	s_3	0.2	0.2 } 0	0.2 } 1		1 1
4	s_4	0.1 } 0	0.2 } 1			0 1 0
5	s_5	0.1 } 1				0 1 1

Κωδικοποίηση Πηγής

- Παράδειγμα (συνέχεια): Το μέσο μήκος των κωδικολέξεων του κώδικά Huffman είναι

$$\bar{L} = \sum_{i=1}^5 P_i \ell_i = 0.4 \times 2 + 0.2 \times 2 + 0.2 \times 2 + 0.1 \times 3 + 0.1 \times 3 = 2.2 \text{ bit}$$

- Η απόδοση του κώδικα είναι

$$\eta = \frac{H(\mathcal{L})}{\bar{L}} = \frac{2.12}{2.2} \approx 96.4\%$$

- Το μέσο μήκος των κωδικολέξεων διαφέρει λιγότερο από 0.1 bit από την εντροπία της πηγής
- Ο κώδικας Huffman είναι βέλτιστος ως προς το μέσο μήκος των κωδικολέξεων

Κωδικοποίηση Πηγής

Κωδικοποίηση Huffman

(Χρήση Κωδικού Δέντρου)

- Διατάσσουμε τα σύμβολα s_1, s_2, \dots, s_n κατά φθίνουσα πιθανότητα $P_1 \geq P_2 \geq \dots \geq P_n$
- Για κάθε σύμβολο δημιουργούμε έναν κόμβο φύλλο
- Από τους δύο χαμηλότερης πιθανότητας κόμβους φύλλα δημιουργούμε ένα νέο, με πιθανότητα το άθροισμα των πιθανοτήτων των προηγούμενων δύο και αναδιατάσσουμε
- Επαναλαμβάνουμε το προηγούμενο βήμα μέχρι να φτάσουμε στη ρίζα του δέντρου
- Σε κάθε διακλάδωση του δέντρου τοποθετούμε αριστερά το 0 και δεξιά το 1
- Διατρέχουμε το δέντρο από την ρίζα προς τα φύλλα και σχηματίζουμε τις κωδικολέξεις

Κωδικοποίηση Πηγής

- Παράδειγμα (συνέχεια): Διακριτή πηγή χωρίς μνήμη παράγει ανεξάρτητα σύμβολα με πιθανότητες $\{0.2, 0.1, 0.2, 0.4, 0.1\}$

s_1	s_2	s_3	s_4	s_5
0.4	0.2	0.2	0.1	0.1


- Να βρεθεί η εντροπία της πηγής και κωδικοποιηθούν τα σύμβολα κατά Huffman, όπου να βρεθεί το μέσο μήκος των bit ανά σύμβολο
- Να γίνει επίλυση με χρήση του δέντρου του κώδικα

Κωδικοποίηση Πηγής

- Παράδειγμα (συνέχεια):

s_1	s_2	s_3	s_4	s_5
0.4	0.2	0.2	0.1	0.1


- ❑ Για κάθε σύμβολο δημιουργούμε έναν κόμβο φύλλο
- ❑ Από τους δύο χαμηλότερης πιθανότητας κόμβους φύλλα δημιουργούμε ένα νέο, με πιθανότητα το άθροισμα των πιθανοτήτων των προηγούμενων δύο και αναδιατάσσουμε



Κωδικοποίηση Πηγής

- Παράδειγμα (συνέχεια):

s_1	s_2	s_3	s_4	s_5
0.4	0.2	0.2	0.1	0.1




- Από τους δύο χαμηλότερης πιθανότητας κόμβους φύλα δημιουργούμε ένα νέο, με πιθανότητα το άθροισμα των πιθανοτήτων των προηγούμενων δύο και αναδιατάσσουμε
- Επαναλαμβάνουμε το προηγούμενο βήμα μέχρι να φτάσουμε στη ρίζα του δέντρου

Κωδικοποίηση Πηγής

● Παράδειγμα (συνέχεια):

s_1	s_2	s_3	s_4	s_5
0.4	0.2	0.2	0.1	0.1




- Από τους δύο χαμηλότερης πιθανότητας κόμβους φύλα δημιουργούμε ένα νέο, με πιθανότητα το άθροισμα των πιθανοτήτων των προηγούμενων δύο και αναδιατάσσουμε
- Επαναλαμβάνουμε το προηγούμενο βήμα μέχρι να φτάσουμε στη ρίζα του δέντρου

Κωδικοποίηση Πηγής

● Παράδειγμα (συνέχεια):

s_1	s_2	s_3	s_4	s_5
0.4	0.2	0.2	0.1	0.1




- Επαναλαμβάνουμε το προηγούμενο βήμα μέχρι να φτάσουμε στη ρίζα του δέντρου

Κωδικοποίηση Πηγής

● Παράδειγμα (συνέχεια):

s_1	s_2	s_3	s_4	s_5
0.4	0.2	0.2	0.1	0.1



- ❑ Σε κάθε διακλάδωση του δέντρου τοποθετούμε αριστερά το 0 και δεξιά το 1
- ❑ Διατρέχουμε το δέντρο από τη ρίζα προς τα φύλλα και σχηματίζουμε τις κωδικολέξεις

Κωδικοποίηση Πηγής

- Παράδειγμα (συνέχεια): Το μέσο μήκος των κωδικολέξεων του κώδικά Huffman στο παράδειγμα που προηγήθηκε είναι

$$\bar{L} = \sum_{i=1}^5 P_i \ell_i = 0.4 \times 1 + 0.2 \times 2 + 0.2 \times 3 + 0.1 \times 4 + 0.1 \times 4 = 2.2 \text{ bit}$$

- Η απόδοση του κώδικα είναι

$$\eta = \frac{H(\mathcal{L})}{\bar{L}} = \frac{2.12}{2.2} \approx 96.4\%$$

- Το μέσο μήκος των κωδικολέξεων διαφέρει λιγότερο από 0.1 bit από την εντροπία της πηγής
- Ο κώδικας που παράχθηκε είναι στιγμιαίος και διαφορετικός σε σχέση με την προηγούμενη επίλυση, αλλά η απόδοση του κώδικά είναι ακριβώς ίδια, δηλαδή οι δύο τρόποι είναι ισοδύναμοι

Κωδικοποίηση Πηγής

- Παράδειγμα: Διακριτή πηγή χωρίς μνήμη παράγει ανεξάρτητα σύμβολα $\mathcal{L} = \{s_1, s_2, s_3\}$ με πιθανότητες εμφάνισης $\{0.4, 0.4, 0.2\}$, αντίστοιχα
- Να βρεθεί η εντροπία της πηγής και κωδικοποιηθούν τα σύμβολα κατά Huffman, όπου να βρεθεί το μέσο μήκος των bit ανά σύμβολο
- Στη συνέχεια, να σχηματιστούν υπερσύμβολα αποτελούμενα από 2 σύμβολα
- Να κωδικοποιηθούν τα υπερσύμβολα κατά Huffman και να βρεθεί το μέσο μήκος των bit ανά σύμβολο

Κωδικοποίηση Πηγής

- Παράδειγμα (συνέχεια): Η εντροπία της διακριτής πηγής χωρίς μνήμη είναι $\{0.4, 0.4, 0.2\}$

$$H(\mathcal{L}) = \sum_{i=1}^3 P_i \log_2 \left(\frac{1}{P_i} \right) = 0.4 \log_2 \left(\frac{1}{0.4} \right) + 0.4 \log_2 \left(\frac{1}{0.4} \right) + 0.2 \log_2 \left(\frac{1}{0.2} \right) \text{ bit} = 1.5219 \text{ bit}$$

- Το μέσο μήκος των κωδικολέξεων του κώδικα Huffman είναι


$$\bar{L} = \sum_{i=1}^3 P_i \ell_i = (0.4 \times 1 + 0.4 \times 2 + 0.2 \times 2) \text{ bit} = 1.6 \text{ bit}$$

- Η απόδοση του κώδικα είναι

$$\eta = \frac{H(\mathcal{L})}{\bar{L}} = \frac{1.5219}{1.6} \approx 95.121\%$$

- Το μέσο μήκος των κωδικολέξεων διαφέρει λιγότερο από 0.1 bit από την εντροπία της πηγής

s_1	s_2	s_3
0.4	0.4	0.2



Κωδικοποίηση Πηγής

- Παράδειγμα (συνέχεια): Κατασκευάζουμε υπερσύμβολα σε μπλοκ καθένα αποτελούμενο από δύο σύμβολα της διακριτής πηγής (πλήθος $3^2 = 9$)
- Το σύνολο των υπερσυμβόλων είναι $\mathcal{L} = \{s_1 s_1, s_1 s_2, s_1 s_3, s_2 s_1, s_2 s_2, s_2 s_3, s_3 s_1, s_3 s_2, s_3 s_3\}$
- Δεδομένης της ανεξαρτησία μεταξύ των s_1, s_2, s_3 , οι πιθανότητες εμφάνισης των υπερσυμβόλων θα είναι το γινόμενο των πιθανοτήτων εμφάνισης των συμβόλων που τα σχηματίζουν
- Συνεπώς, τα υπερσύμβολα χαρακτηρίζονται από τις παρακάτω πιθανότητες

Υπερσύμβολα	σ_1	σ_2	σ_5	σ_3	σ_4	σ_6	σ_7	σ_8	σ_9
	$s_1 s_1$	$s_1 s_2$	$s_1 s_3$	$s_2 s_1$	$s_2 s_2$	$s_2 s_3$	$s_3 s_1$	$s_3 s_2$	$s_3 s_3$
Πιθανότητες	$P_1 P_1$	$P_1 P_2$	$P_1 P_3$	$P_2 P_1$	$P_2 P_1$	$P_2 P_3$	$P_3 P_1$	$P_3 P_2$	$P_3 P_3$
	0.16	0.16	0.08	0.16	0.16	0.08	0.08	0.08	0.04

Κωδικοποίηση Πηγής

- Όπως αναμένεται, η εντροπία των υπερσυμβόλων θα είναι διπλάσια της εντροπίας της πηγής

- Η εντροπία μπορεί να υπολογιστεί ως

$$\begin{aligned} H(\mathcal{L}^2) &= \sum_{i=1}^9 P_i \log_2 \left(\frac{1}{P_i} \right) = \\ &= 4 \times 0.16 \log_2 \left(\frac{1}{0.16} \right) + 4 \times 0.08 \log_2 \left(\frac{1}{0.08} \right) + 0.04 \log_2 \left(\frac{1}{0.04} \right) \text{ bit} = 3.0439 \text{ bit} \end{aligned}$$


- Δηλαδή, όντως, επαληθεύεται η ιδιότητα $H(\mathcal{L}^2) = 2 H(\mathcal{L})$

Υπερσύμβολα	σ_1	σ_2	σ_5	σ_3	σ_4	σ_6	σ_7	σ_8	σ_9
	$s_1 s_1$	$s_1 s_2$	$s_1 s_3$	$s_2 s_1$	$s_2 s_2$	$s_2 s_3$	$s_3 s_1$	$s_3 s_2$	$s_3 s_3$
Πιθανότητες	$P_1 P_1$	$P_1 P_2$	$P_1 P_3$	$P_2 P_1$	$P_2 P_1$	$P_2 P_3$	$P_3 P_1$	$P_3 P_2$	$P_3 P_3$
	0.16	0.16	0.08	0.16	0.16	0.08	0.08	0.08	0.04

Κωδικοποίηση Πηγής

● Δέντρο Κώδικα Huffman

Υπερσύμβολα	σ_1	σ_2	σ_3	σ_4	σ_5	σ_6	σ_7	σ_8	σ_9
Πιθανότητες	0.16	0.16	0.16	0.16	0.08	0.08	0.08	0.08	0.04




- Ο πρώτος κόμβος σχηματίζεται από τα 2 πρώτα σύμβολα με τις μικρότερες πιθανότητες

Κωδικοποίηση Πηγής

● Δέντρο Κώδικα Huffman

Υπερσύμβολα	σ_1	σ_2	σ_3	σ_4	σ_5	σ_6	σ_7	σ_8	σ_9
Πιθανότητες	0.16	0.16	0.16	0.16	0.08	0.08	0.08	0.08	0.04




- Ο κάθε επόμενος κόμβος σχηματίζεται από τα 2 σύμβολα με τις μικρότερες πιθανότητες που έχουν εναπομείνει

Κωδικοποίηση Πηγής

● Δέντρο Κώδικα Huffman

Υπερσύμβολα	σ_1	σ_2	σ_3	σ_4	σ_5	σ_6	σ_7	σ_8	σ_9
Πιθανότητες	0.16	0.16	0.16	0.16	0.08	0.08	0.08	0.08	0.04

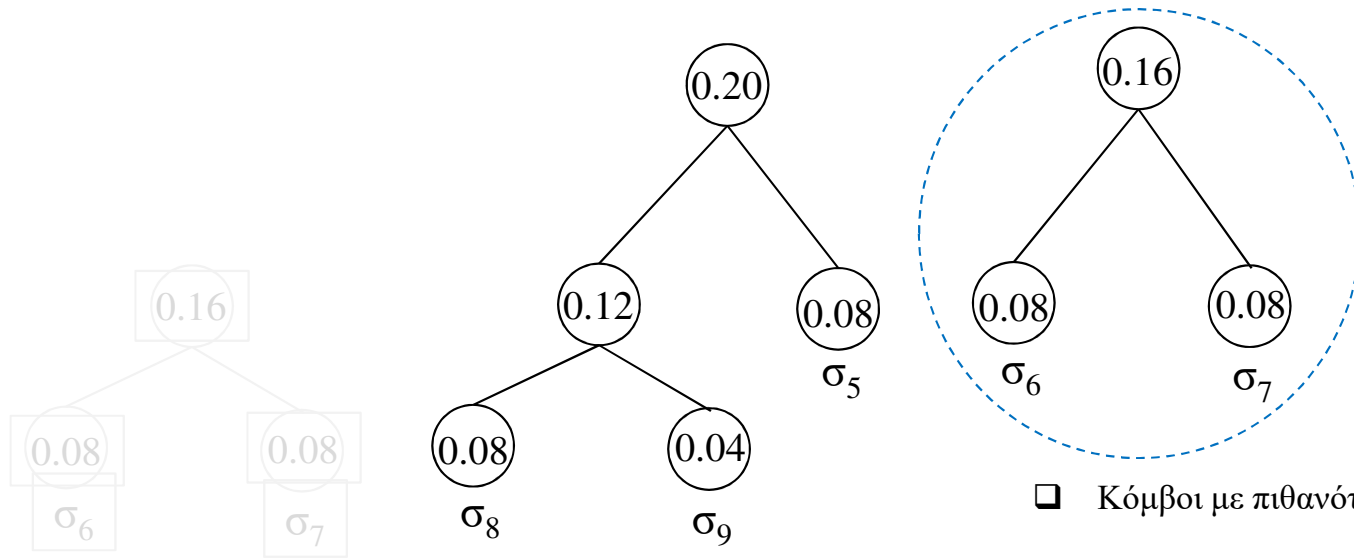


□ Ο κάθε επόμενος κόμβος σχηματίζεται από τα 2 σύμβολα με τις μικρότερες πιθανότητες που έχουν εναπομείνει

Κωδικοποίηση Πηγής

● Δέντρο Κώδικα Huffman

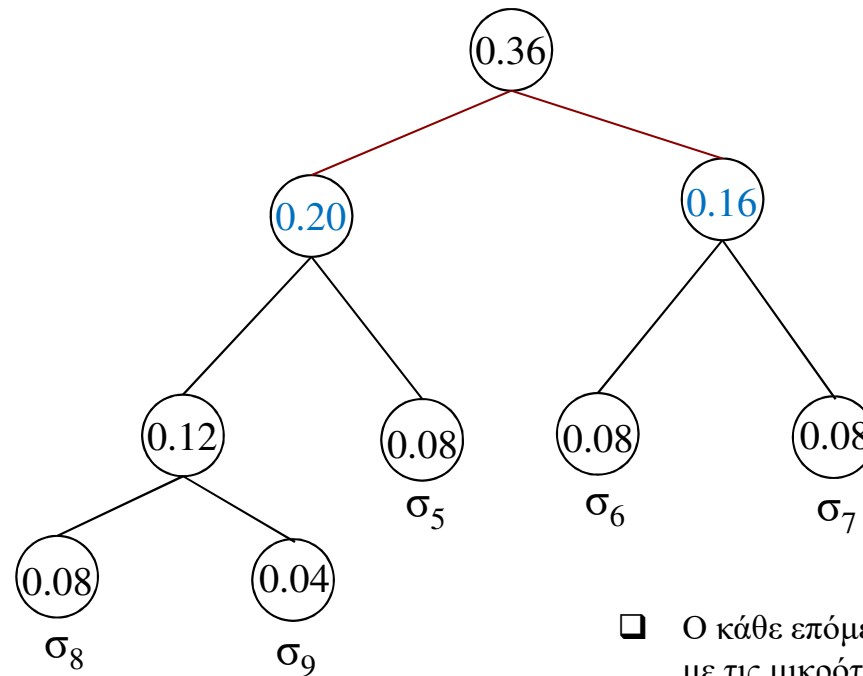
Υπερσύμβολα	σ_1	σ_2	σ_3	σ_4	σ_5	σ_6	σ_7	σ_8	σ_9
Πιθανότητες	0.16	0.16	0.16	0.16	0.08	0.08	0.08	0.08	0.04



Κωδικοποίηση Πηγής

- Δέντρο Κώδικα Huffman

Υπερσύμβολα	σ_1	σ_2	σ_3	σ_4	σ_5	σ_6	σ_7	σ_8	σ_9
Πιθανότητες	0.16	0.16	0.16	0.16	0.08	0.08	0.08	0.08	0.04

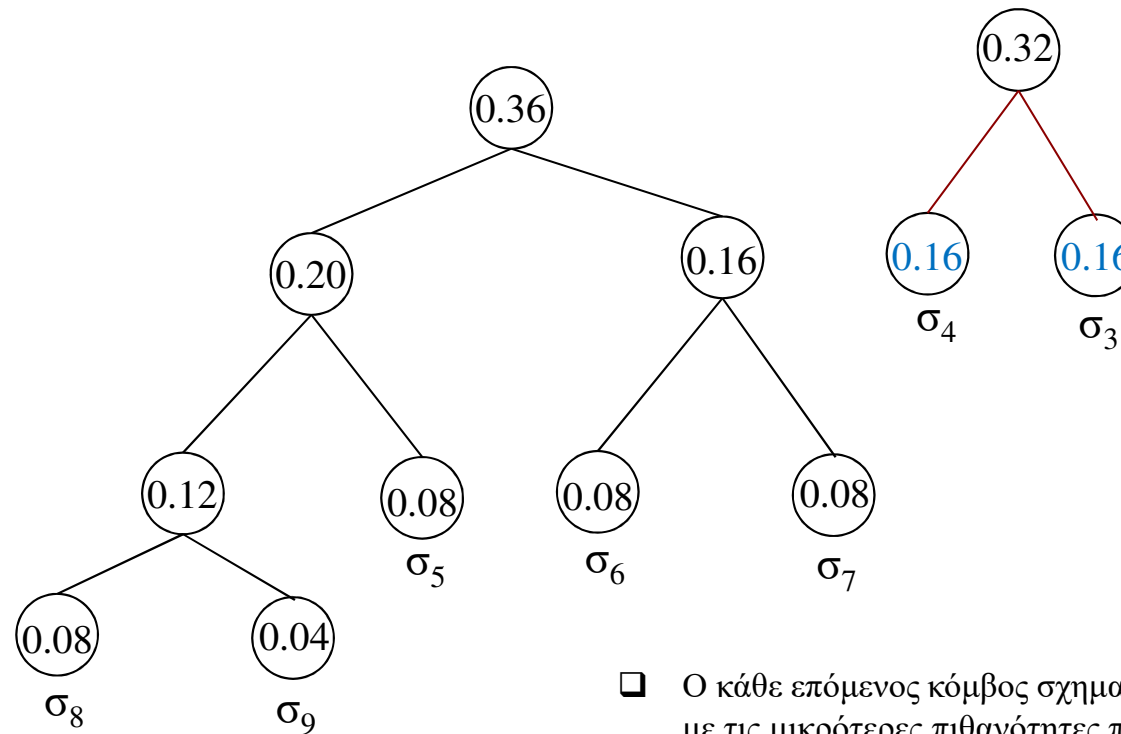


- Ο κάθε επόμενος κόμβος σχηματίζεται από τα 2 σύμβολα με τις μικρότερες πιθανότητες που έχουν εναπομείνει

Κωδικοποίηση Πηγής

● Δέντρο Κώδικα Huffman

Υπερσύμβολα	σ_1	σ_2	σ_3	σ_4	σ_5	σ_6	σ_7	σ_8	σ_9
Πιθανότητες	0.16	0.16	0.16	0.16	0.08	0.08	0.08	0.08	0.04

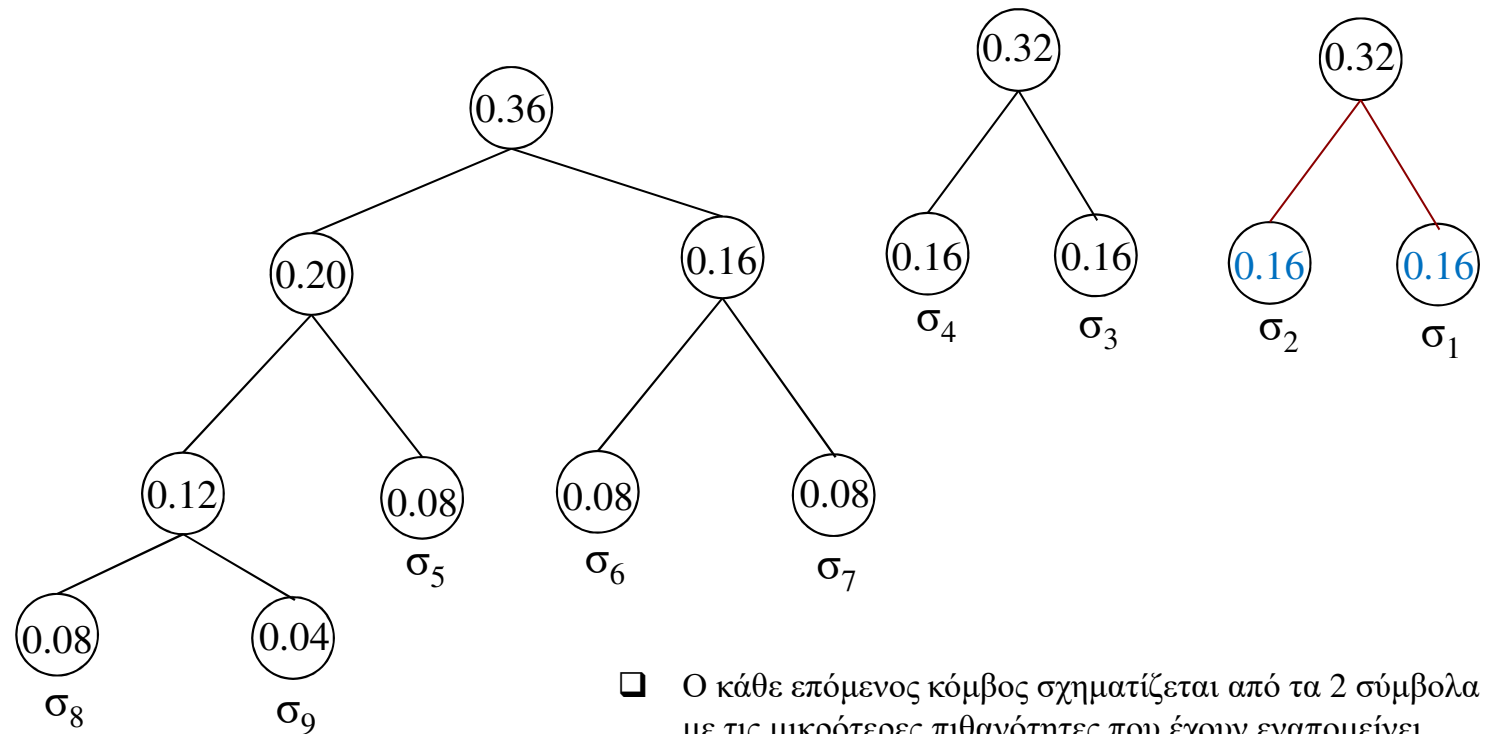


□ Ο κάθε επόμενος κόμβος σχηματίζεται από τα 2 σύμβολα με τις μικρότερες πιθανότητες που έχουν εναπομείνει

Κωδικοποίηση Πηγής

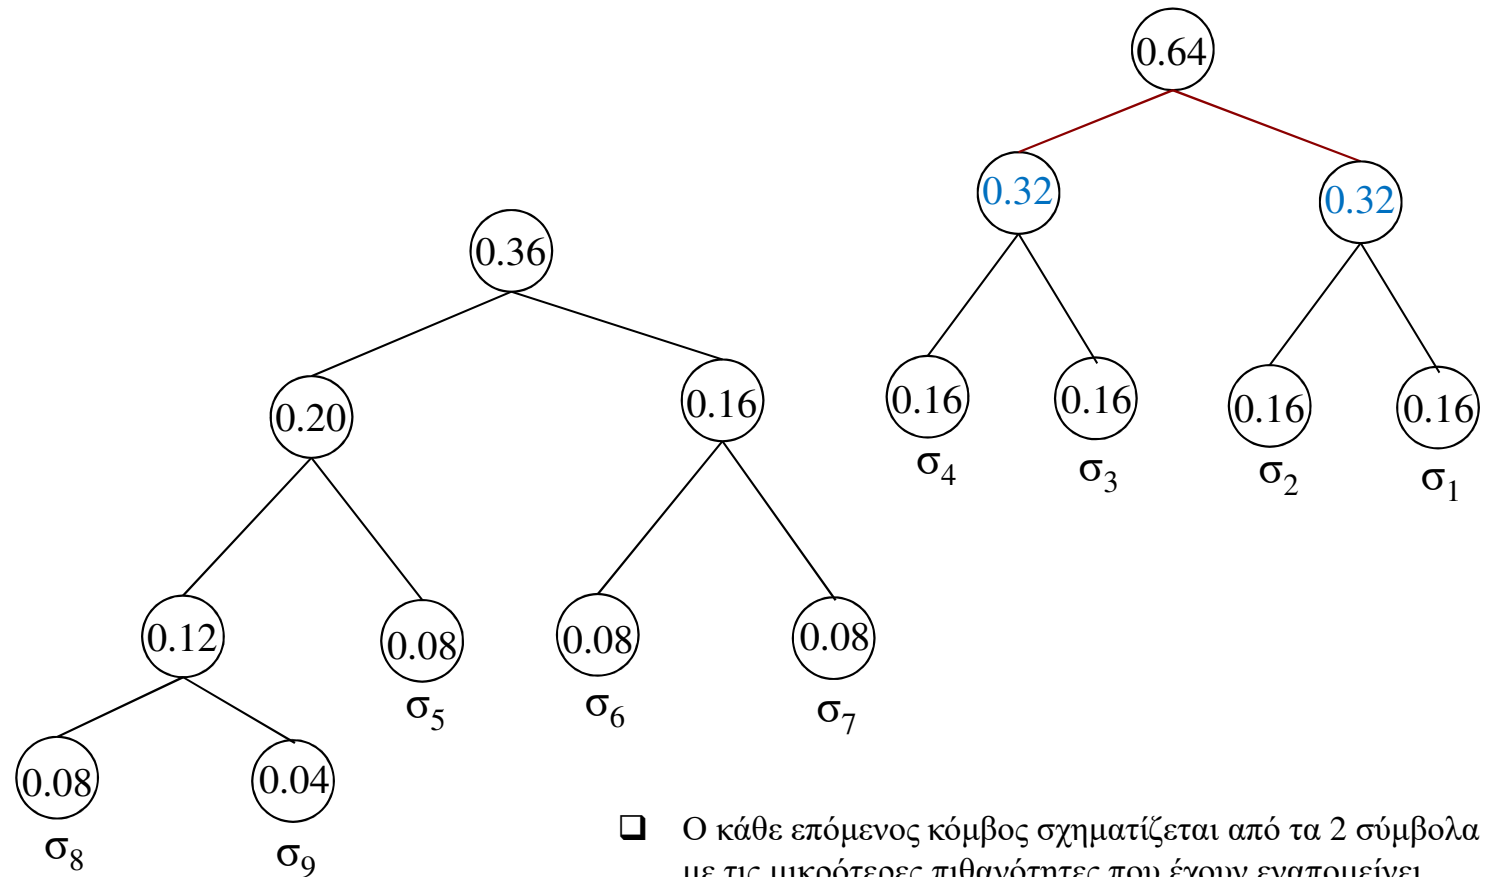
● Δέντρο Κώδικα Huffman

Υπερσύμβολα	σ_1	σ_2	σ_3	σ_4	σ_5	σ_6	σ_7	σ_8	σ_9
Πιθανότητες	0.16	0.16	0.16	0.16	0.08	0.08	0.08	0.08	0.04



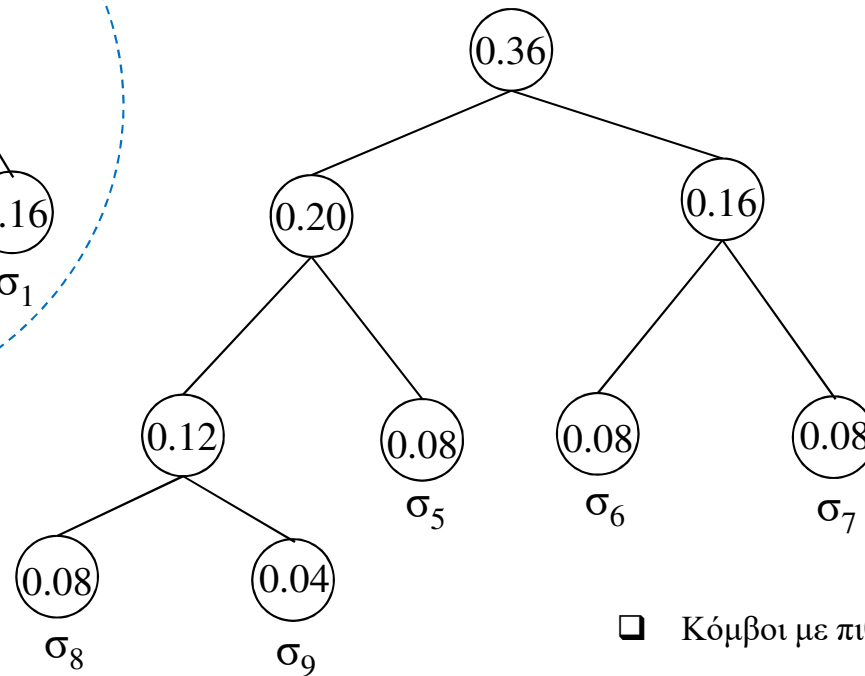

Κωδικοποίηση Πηγής

- Δέντρο Κώδικα Huffman



Κωδικοποίηση Πηγής

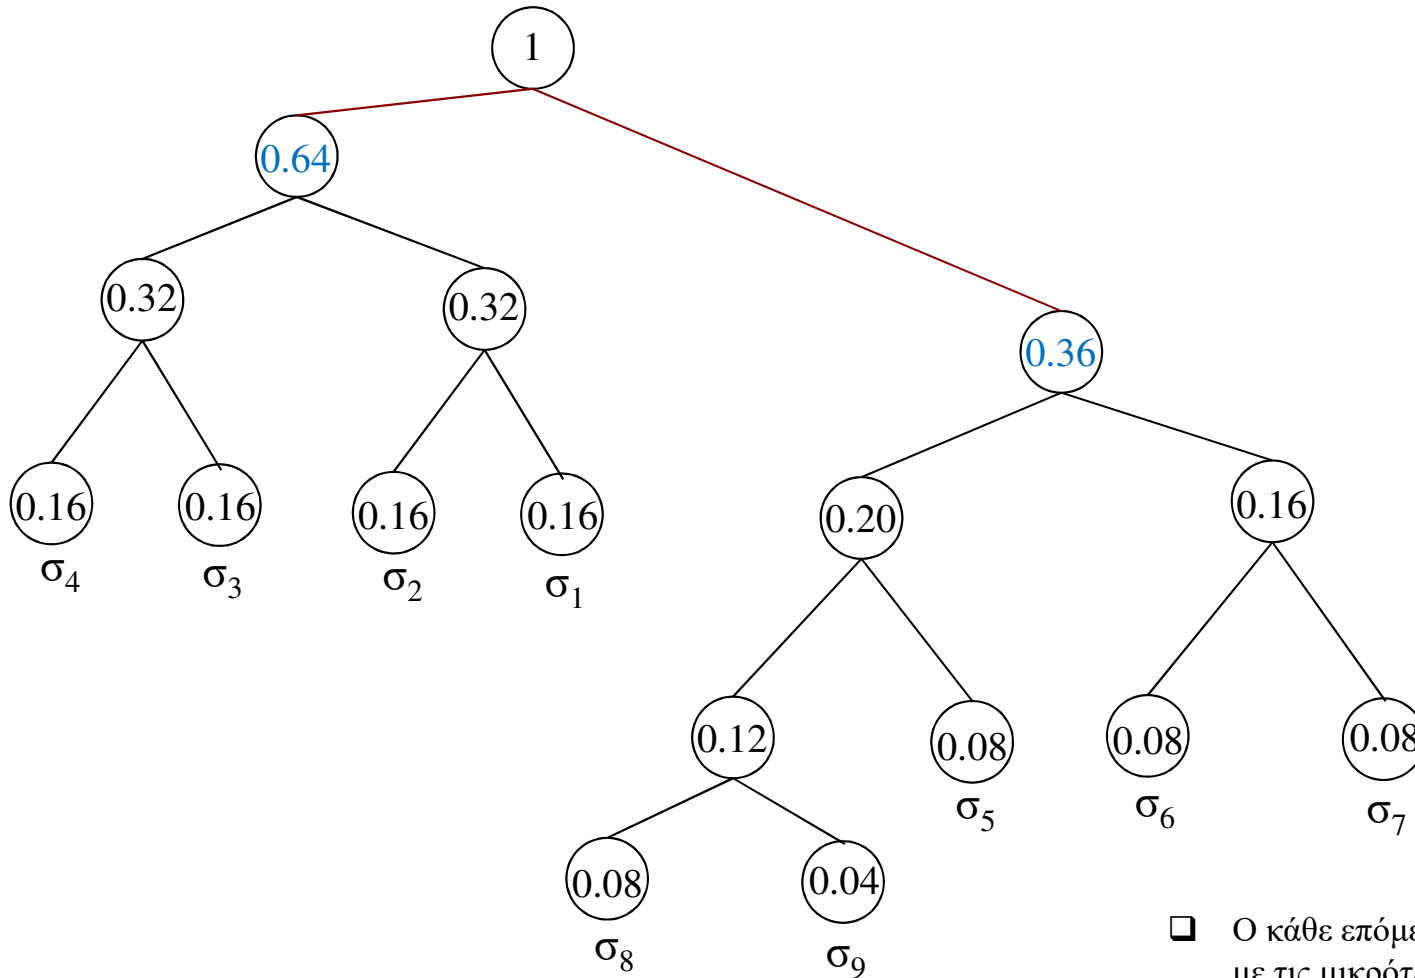
● Δέντρο Κώδικα Huffman



□ Κόμβοι με πιθανότητες μικρότερες ή ίσες τοποθετούνται δεξιά

Κωδικοποίηση Πηγής

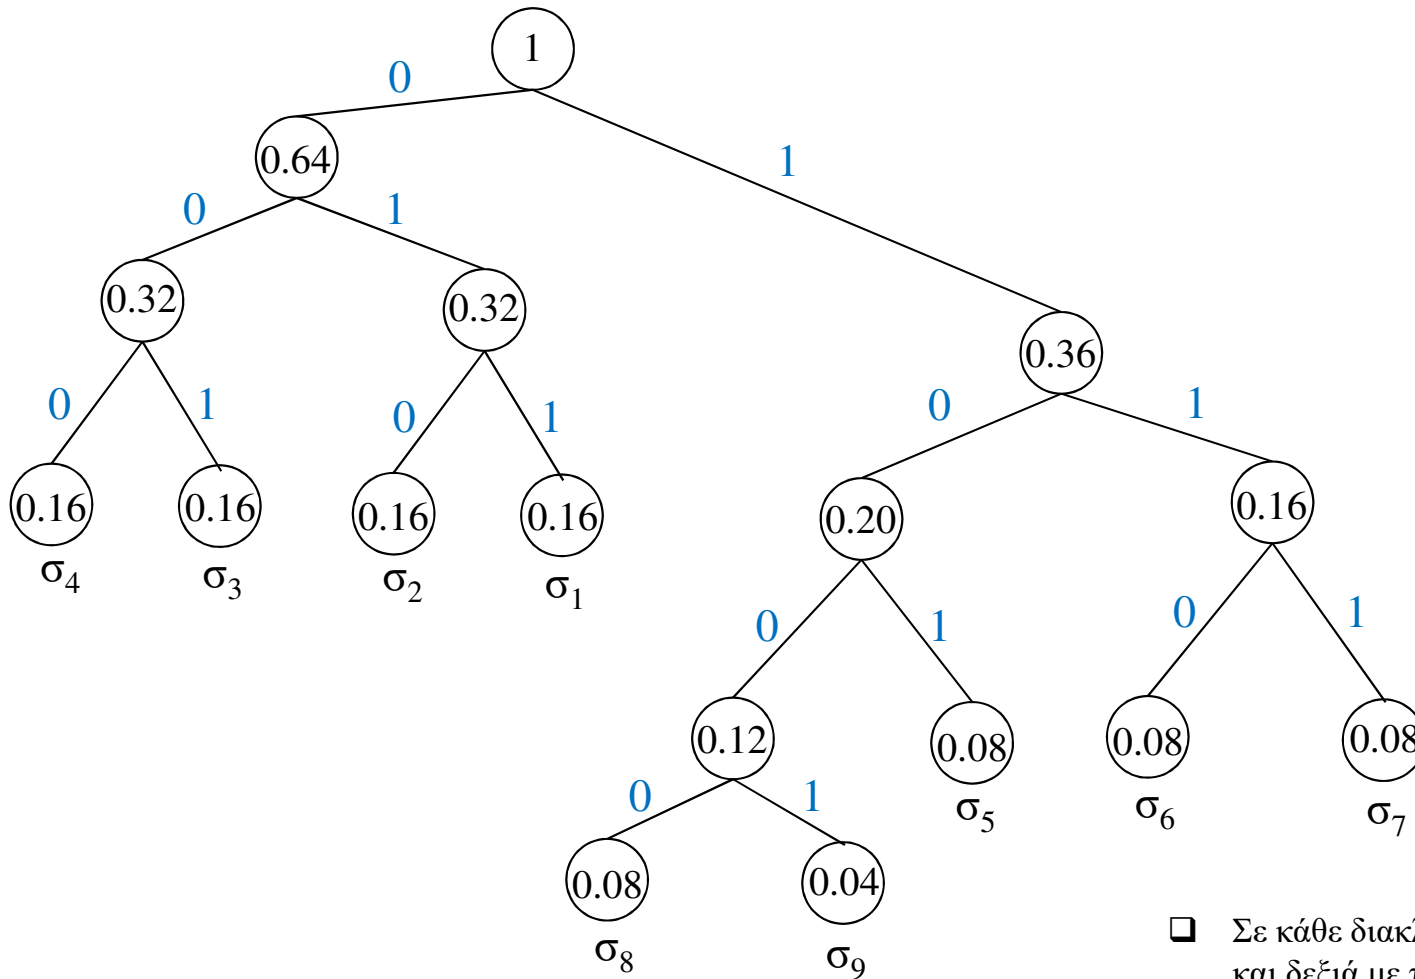
● Δέντρο Κώδικα Huffman



□ Ο κάθε επόμενος κόμβος σχηματίζεται από τα 2 σύμβολα με τις μικρότερες πιθανότητες που έχουν εναπομείνει

Κωδικοποίηση Πηγής

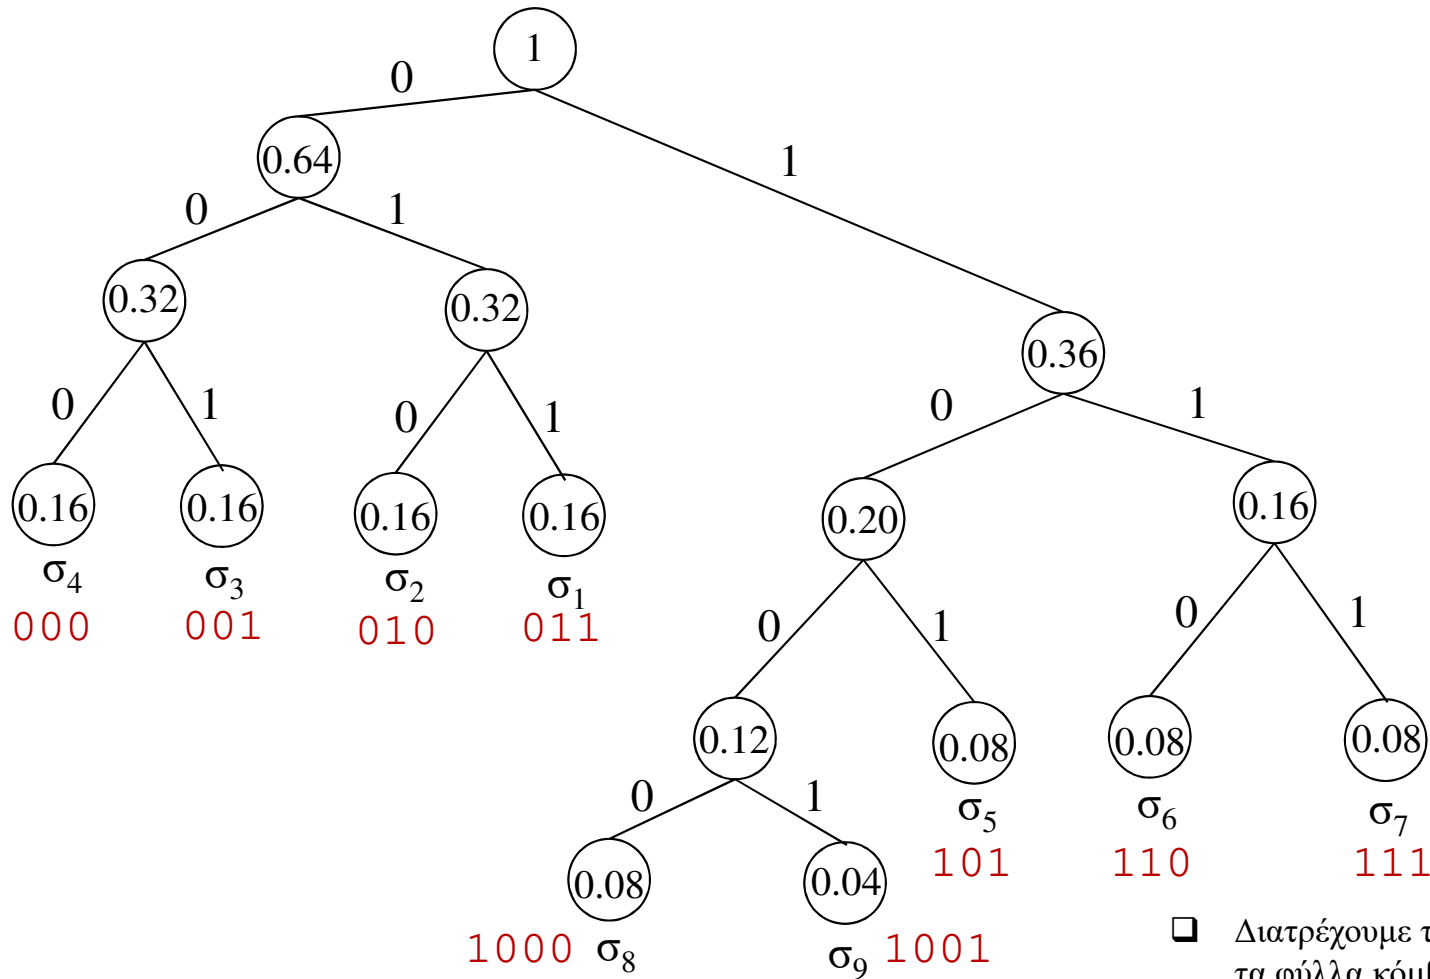
● Δέντρο Κώδικα Huffman



□ Σε κάθε διακλάδωση αριστερά σημειώνουμε με το bit 0 και δεξιά με το bit 1

Κωδικοποίηση Πηγής

● Δέντρο Κώδικα Huffman



□ Διατρέχουμε τις διαδρομές από τη ρίζα του δέντρου προς τα φύλλα κόμβους και βρίσκουμε τις κωδικολέξεις

Κωδικοποίηση Πηγής

- Με βάση τις πιθανότητες και τα μήκη των κωδικολέξεων, τα οποία συνοψίζονται στον παρακάτω πίνακα, μπορούμε να υπολογίσουμε το μέσο μήκος ανά υπερσύμβολο

Υπερσύμβολα	σ_1	σ_2	σ_3	σ_4	σ_5	σ_6	σ_7	σ_8	σ_9
Πιθανότητες P_i	0.16	0.16	0.16	0.16	0.08	0.08	0.08	0.08	0.04
Κωδικολέξεις $c(\sigma_i)$	011	010	001	000	101	110	111	1000	1001
Μήκος l_i	3	3	3	3	3	3	3	4	4

- Το μέσο μήκος σε bit των κωδικολέξεων ανά υπερσύμβολο είναι

$$\mathbb{E} \langle \ell(s_1, s_2) \rangle = \sum_{i=1}^9 P_i l_i = (4 \times 0.16 \times 3 + 4 \times 0.08 \times 3 + 0.04 \times 1) \text{ bit} = 3.12 \text{ bit}$$

Κωδικοποίηση Πηγής

- Δηλαδή, δεδομένου ότι κάθε υπερσύμβολο περιέχει 2 σύμβολα, το μέσο μήκος των κωδικολέξεων ανά σύμβολο είναι

$$\bar{L}_2 = \frac{1}{2} \mathbb{E} \langle \ell(s_1, s_2) \rangle = 1.56 \text{ bit}$$

- Η εντροπία της πηγής έχει υπολογιστεί $H(\mathcal{L}) = 1.5219 \text{ bit}$ και το μέσο μήκος των κωδικολέξεων, εφαρμόζοντας κωδικοποίηση Huffman στα σύμβολα της πηγής, έχει βρεθεί 1.6 bit
- Συνεπώς, δημιουργώντας μπλοκ των 2 συμβόλων, βελτιώθηκε το μέσο μήκος των κωδικολέξεων κατά 0.04 bit