

ΣΥΣΤΗΜΑΤΑ ΑΝΑΜΟΝΗΣ

Queuing Systems

Εφαρμογές Θεωρήματος Jackson:
(i) Δίκτυα Μεταγωγής Πακέτου
(ii) Υπολογιστικά Μοντέλα Πολυεπεξεργασίας

Βασίλης Μάγκλαρης
maglaris@netmode.ntua.gr

3/5/2017

ΑΝΟΙΚΤΑ ΔΙΚΤΥΑ ΕΚΘΕΤΙΚΩΝ ΟΥΡΩΝ (Επανάληψη)

ΘΕΩΡΗΜΑ JACKSON

Παραδοχές

- Ανοικτό δίκτυο M **δικτυακών κόμβων εξυπηρέτησης κορμού** (ουρών αναμονής) Q_i , $i = 1, 2, \dots, M$ με εκθετικούς ρυθμούς εξυπηρέτησης μ_i
- Αφίξεις πελατών (πακέτων) από εξωτερικές πηγές (sources) άμεσα συνδεδεμένες στον δικτυακό κόμβο κορμού Q_s προς εξωτερικούς προορισμούς (destinations) άμεσα συνδεδεμένους στον δικτυακό κόμβο κορμού Q_d :
Ανεξάρτητες ροές Poisson μέσου ρυθμού γ_{sd} όπου $s, d \in \{1, 2, \dots, M\}$
- Εσωτερική **δρομολόγηση** (routing) με τυχαίο τρόπο και πιθανότητα δρομολόγησης πελάτη από τον κόμβο κορμού (ουρά) Q_i στον κόμβο Q_j : r_{ij}
- Έστω $\delta_{sd}(i) = 1$ αν πελάτες (πακέτα) της ροής (s, d) διακινούνται μέσα από τον κόμβο κορμού Q_i ή αλλιώς $\delta_{sd}(i) = 0$. Τότε τον κόμβο εξυπηρέτησης Q_i διαπερνούν ροές με συνολικό μέσο ρυθμό $\lambda_i = \sum_{d=1}^M \sum_{s=1}^M \gamma_{sd} \delta_{sd}(i)$
- Οι χρόνοι εξυπηρέτησης πελατών όπως διαπερνούν το δίκτυο δεν διατηρούν την τιμή τους (έλλειψη μνήμης) αλλά αποκτούν χρόνο εξυπηρέτησης ανάλογα με την κατανομή του κάθε εξυπηρετητή (**Kleinrock's Independence Assumption**, επαληθευμένα με προσομοιώσεις σε δίκτυα με όχι απλοϊκή τοπολογία)

ΑΝΟΙΚΤΑ ΔΙΚΤΥΑ ΕΚΘΕΤΙΚΩΝ ΟΥΡΩΝ (Επανάληψη)

ΘΕΩΡΗΜΑ JACKSON

Αποτέλεσμα



- Κατάσταση του δικτύου: Διάνυσμα $\mathbf{n} = (n_1, n_2, \dots, n_M)$ αριθμού πελατών n_i στις ουρές (κόμβους κορμού) Q_i
- Η **Εργοδική Πιθανότητα** των καταστάσεων \mathbf{n} (αν υπάρχει) έχει μορφή γινομένου (product form) **ανεξαρτήτων ουρών M/M/1**
$$P(\mathbf{n}) = P(n_1, n_2, \dots, n_M) = P(n_1)P(n_2) \dots P(n_M)$$
$$P(n_i) = (1 - \rho_i)\rho_i^{n_i} \text{ με } \rho_i = \lambda_i/\mu_i$$

όπου λ_i ο συνολικός μέσος ρυθμός (**Poisson**) των πελατών που διαπερνούν τον κόμβο κορμού (ουρά) Q_i με ρυθμό εκθετικής εξυπηρέτησης μ_i
- Ουρά (κόμβος κορμού) συμφόρησης: Η Q_i με το μέγιστο ρ_i
- Μέσος αριθμός πελατών (πακέτων) στο δίκτυο: $E(\mathbf{n}) = \sum_{i=1}^M E(n_i) = \sum_{i=1}^M \frac{\rho_i}{1-\rho_i}$
- Μέση καθυστέρηση τυχαίου πακέτου από άκρο σε άκρο: $E(T) = E(\mathbf{n})/\gamma$ (**τύπος Little**)
όπου γ ο συνολικός μέσος ρυθμός πελατών (**Poisson**) που εισέρχονται στο δίκτυο από εξωτερικές πηγές (**network throughput**) $\gamma = \sum_{s=1}^M \sum_{d=1}^M \gamma_{sd}$
- Μέση καθυστέρηση τυχαίου πακέτου από κόμβο s σε κόμβο d : $E(T_{sd}) = \sum_{i=1}^M \delta_{sd}(i) \frac{1/\mu_i}{1-\rho_i}$

ΠΑΡΑΔΕΙΓΜΑ 1: ΔΙΚΤΥΟ ΜΕΤΑΓΩΓΗΣ ΠΑΚΕΤΟΥ (1/4)

- Θεωρούμε ένα δίκτυο μεταγωγής πακέτων (**Internet – Intranet**) 4 κόμβων (**routers**) κορμού όπως στο σχήμα
 - Όλες οι γραμμές κορμού (FDX) θεωρούνται χωρητικότητας $C_i = C = 10$ Gbits/sec. Τα πακέτα έχουν μήκος L εκθετικά κατανομημένο με μέση τιμή $E(L) = 1000$ bits (θεωρείστε εκθετική κατανομή)
 - Μεταξύ κόμβων πηγής και προορισμού τα πακέτα προσφέρονται σε ροές Poisson με ίσους συνολικούς ρυθμούς r packets/sec (από άκρο σε άκρο μεταξύ κόμβων κορμού, σύνολο 3×4 ροές)
 - Πακέτα από το A στο C και αντίστροφα δρομολογούνται με τυχαία δρομολόγηση p , $(1 - p)$ στους δύο ισότιμους δρόμους: $(A - B - C)$ και $(A - D - C)$. Θεωρούμε πως $p = 0.5$
 - Πακέτα μεταξύ κόμβων κορμού κατευθείαν συνδεδεμένων $(A - B)$, $(A - D)$, $(B - D)$, $(B - C)$, $(D - C)$ δρομολογούνται κατευθείαν
- **(1)** Ζητείται ο ρυθμός των 12 ροών r ώστε η γραμμή συμφόρησης (με τη μέγιστη χρησιμοποίηση) να είναι 50%
- **(2)** Με το r του **(1)** ζητείται η μέση καθυστέρηση από άκρο σε άκρο στο δίκτυο κορμού ενός τυχαίου πακέτου

ΟΔΗΓΙΑ: Οι FDX γραμμές του δικτύου κορμού αναλύονται σε δύο ουρές με ροές πακέτων συνολικού μέσου ρυθμού λ_i (προκύπτει από την δρομολόγηση πακέτων) και μέσου ρυθμού εκθετικής εξυπηρέτησης $\mu_i = C_i/E(L)$. Το ανοικτό δίκτυο ουρών (**επόμενη διαφάνεια**) αναλύεται σαν **δίκτυο ανεξαρτήτων ουρών M/M/1** με το **Θεώρημα του Jackson**

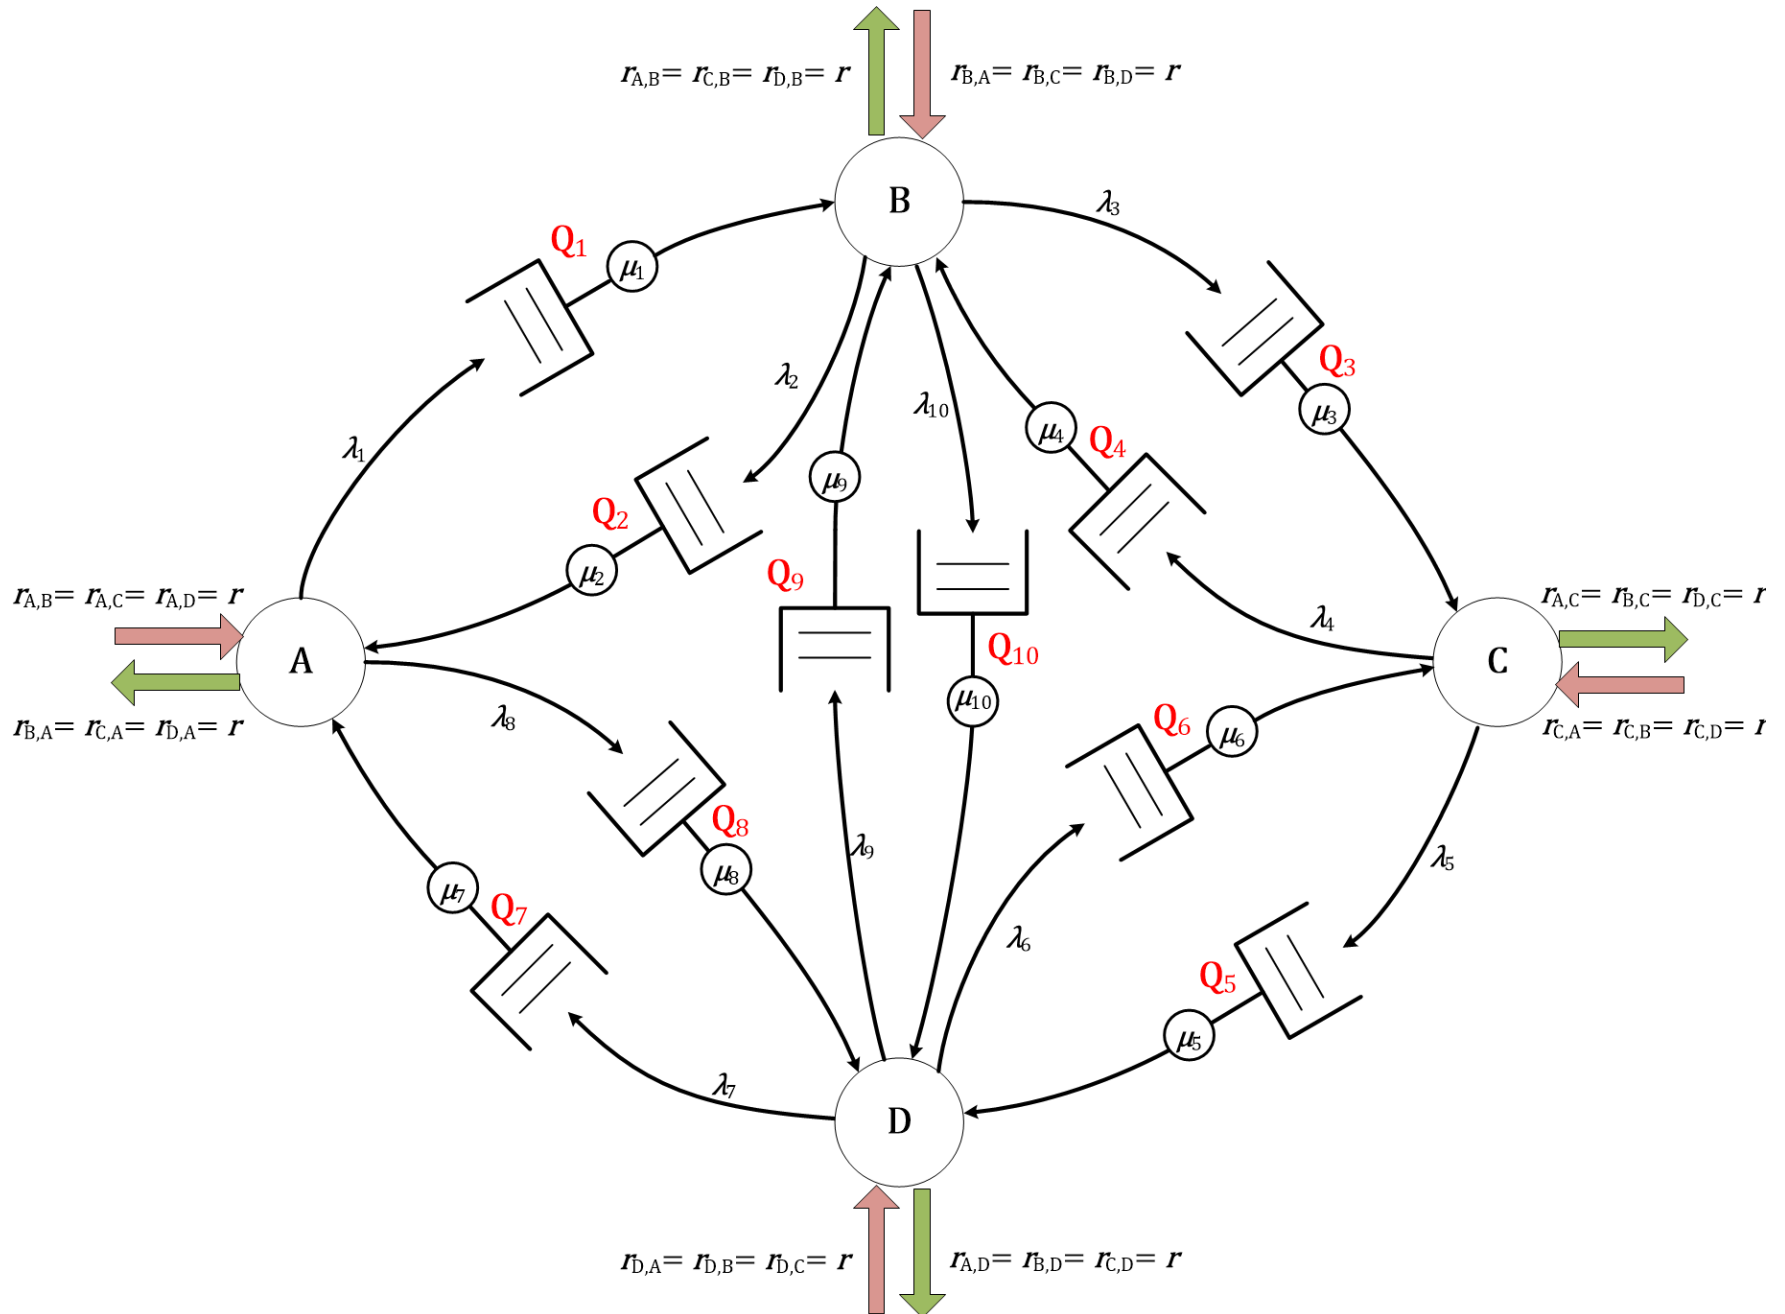


Κόμβος Δικτύου Κορμού
(Δρομολογητής Κορμού, Backbone Router, Packet Switch)



Κόμβος Εισόδου
(H/Y, Access Node, Customer Network - LAN)

ΠΑΡΑΔΕΙΓΜΑ 1: ΔΙΚΤΥΟ ΜΕΤΑΓΩΓΗΣ ΠΑΚΕΤΟΥ (2/4)



ΠΑΡΑΔΕΙΓΜΑ 1 (3/4)

Απάντηση στο Ερώτημα (1)

Με πιθανότητα διαχωρισμού $p = 0.5$, οι ρυθμοί λ_i (packets/sec) στις 10 ανεξάρτητες (M/M/1) ουρές Q_1, Q_2, \dots, Q_{10} (**κατευθυντικές συνδέσεις/γραμμές μεταξύ κόμβων κορμού του δικτύου**) είναι:

$$\lambda_1 = r_{A,B} + pr_{A,C} = 1.5r, \lambda_2 = r_{B,A} + pr_{C,A} = 1.5r$$

$$\lambda_3 = r_{B,C} + pr_{A,C} = 1.5r, \lambda_4 = r_{C,B} + pr_{C,A} = 1.5r$$

$$\lambda_5 = r_{C,D} + (1-p)r_{A,C} = 1.5r, \lambda_6 = r_{D,C} + (1-p)r_{C,A} = 1.5r$$

$$\lambda_7 = r_{D,A} + (1-p)r_{C,A} = 1.5r, \lambda_8 = r_{A,D} + (1-p)r_{A,C} = 1.5r$$

$$\lambda_9 = r_{D,B} = r, \lambda_{10} = r_{B,D} = r$$

Οι ρυθμοί εξυπηρέτησης μ_i (packets/sec) και οι εντάσεις φορτίου $\rho_i = \lambda_i/\mu_i$ (Erlangs) είναι:

$$\mu_i = C/E(L) = (10 \times 10^9)/10^3 = 10^7 \text{ packets/sec}$$

$$\rho_1 = \rho_2 = \dots = \rho_8 = 1.5r \times 10^{-7}, \rho_9 = \rho_{10} = r \times 10^{-7} \text{ Erlangs}$$

Οι **γραμμές συμφόρησης** είναι οι αμφίδρομες γραμμές διασύνδεσης μεταξύ των κόμβων A – B, B – C, C – D, D – A με $\rho_i = 1.5r \times 10^{-7}$ Erlangs

Άρα για να έχουν οι γραμμές συμφόρησης ένταση φορτίου 0.5 Erlangs πρέπει οι ρυθμοί ροών πακέτων r να ικανοποιούν τη σχέση $1.5r \times 10^{-7} = 0.5 \Rightarrow r = 10^7/3$ πακέτα/sec

οπότε $\rho_1 = \dots = \rho_8 = 1/2$ Erlangs (**γραμμές συμφόρησης**) και $\rho_9 = \rho_{10} = 1/3$ Erlangs

ΠΑΡΑΔΕΙΓΜΑ 1 (4/4)

Απάντηση στο Ερώτημα (2)

Το συνολικό προσφερόμενο φορτίο από άκρο σε άκρο γ είναι:

$$\begin{aligned}\gamma &= r_{A,B} + r_{A,C} + r_{A,D} + r_{B,A} + r_{B,C} + r_{B,D} + r_{C,A} + r_{C,B} + r_{C,D} + r_{D,A} + r_{D,B} + r_{D,C} \Rightarrow \\ \gamma &= 12r = 4 \times 10^7 \text{ packets/sec}\end{aligned}$$

Ο μέσος αριθμός πακέτων στα συστήματα Q_1, \dots, Q_{10} δίνονται από $E(n_i) = \rho_i / (1 - \rho_i)$:

$$E(n_1) = \dots = E(n_8) = 1, \quad E(n_9) = E(n_{10}) = 0.5 \text{ packets}$$

$$\text{και } E(\mathbf{n}) = \sum_{i=1}^{10} E(n_i) = 8 \times 1 + 2 \times 0.5 = 9 \text{ packets}$$

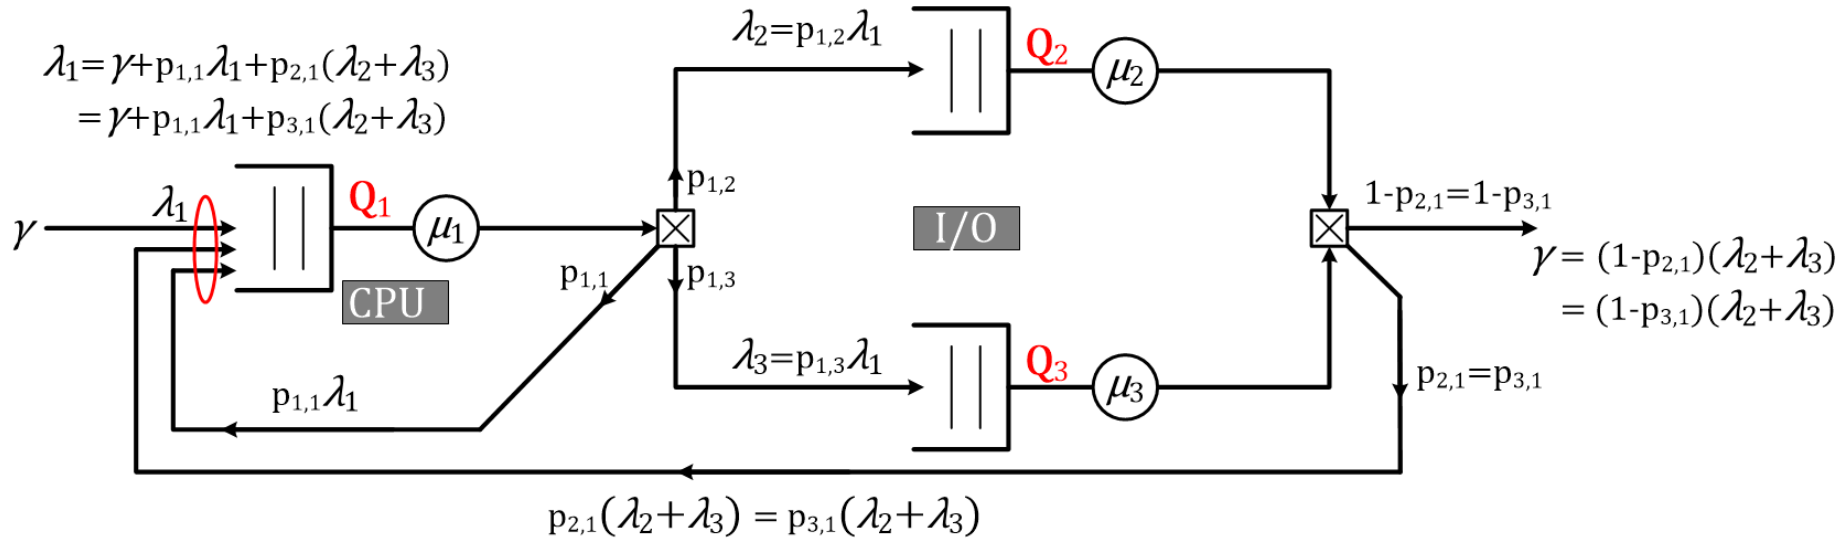
Η μέση καθυστέρηση τυχαίου πακέτου από άκρο σε άκρο είναι από τον τύπο του **Little**:

$$E(T) = E(\mathbf{n}) / \gamma = 9 / (4 \times 10^7) \text{ sec}$$

Η μέση καθυστέρηση τυχαίου πακέτου από το κόμβο A στο κόμβο C δίνεται από:

$$\begin{aligned}E(T_{A,C}) &= p \{E(T_{A,B}) + E(T_{B,C})\} + (1 - p) \{E(T_{A,D}) + E(T_{D,C})\} = \\ &= p \{1 / (\mu_1 - \lambda_1) + 1 / (\mu_3 - \lambda_3)\} + (1 - p) \{1 / (\mu_8 - \lambda_8) + 1 / (\mu_6 - \lambda_6)\} = 4 / 10^7 \text{ sec}\end{aligned}$$

ΠΑΡΑΔΕΙΓΜΑ 2: ΥΠΟΛΟΓΙΣΤΙΚΟ ΣΥΣΤΗΜΑ (1/3)



Θεωρείστε υπολογιστικό σύστημα που εξυπηρετεί κατά μέσο όρο γ εντολές/sec που υποβάλλονται σαν διαδικασία Poisson. Το σύστημα αποτελείται από μια CPU που εξυπηρετεί την εντολή επιμερισμένη σε τμήματα (quanta ή time-slices) και υποσύστημα I/O (δύο δίσκοι) που εξυπηρετεί επαναλαμβανόμενες ενδιάμεσες κλήσεις σχετικές με την εντολή (π.χ. για ανταλλαγή δεδομένων και αναζήτηση υποπρογραμμάτων), ενώ μεσολαβεί για την τελική έξοδο - απάντηση

ΠΑΡΑΔΕΙΓΜΑ 2: ΥΠΟΛΟΓΙΣΤΙΚΟ ΣΥΣΤΗΜΑ (2/3)

- Κάθε εντολή εξυπηρετείται από την CPU του συστήματος, επιμερισμένη σε N_{CPU} τμήματα (quanta ή time-slices) την εξυπηρέτηση των οποίων ακολουθεί κλήση I/O (ενδιάμεση ή τελική). Το υποσύστημα εξυπηρέτησης CPU αναπαρίσταται σαν ουρά αναμονής Q_1 με εκθετική εξυπηρέτηση ρυθμού μ_1 quanta/sec

- Η τυχαία μεταβλητή N_{CPU} έχει μέσο όρο $E(N_{CPU})$ quanta και αναπαρίσταται σαν ανάδραση στο υποσύστημα CPU με τυχαία πιθανότητα $p_{1,1}$

$$E(N_{CPU}) = (1 - p_{1,1}) + 2p_{1,1}(1 - p_{1,1}) + 3p_{1,1}^2(1 - p_{1,1}) + 4p_{1,1}^3(1 - p_{1,1}) + \dots = 1/(1 - p_{1,1})$$

$$p_{1,1} = \frac{E(N_{CPU}) - 1}{E(N_{CPU})}$$

- Την επεξεργασία των τμημάτων N_{CPU} μιας εντολής ακολουθεί κλήση I/O. Το υποσύστημα I/O αποτελείται από δύο συστήματα εξυπηρέτησης τα οποία αναπαρίστανται σαν ουρές αναμονής Q_2 και Q_3 με εκθετική εξυπηρέτηση ρυθμών μ_2 και μ_3 κλήσεις/sec. Η επιλογή Q_2 ή Q_3 γίνεται τυχαία με πιθανότητες $p_{1,2}$ και $p_{1,3}$ αντίστοιχα, $p_{1,1} + p_{1,2} + p_{1,3} = 1$

- Θεωρούμε πως κάθε εντολή παράγει κατά μέσο όρο $E(N_{I/O})$ κλήσεις οι οποίες είτε επανέρχονται στο υποσύστημα CPU με πιθανότητες $p_{2,1} = p_{3,1}$ ή ολοκληρώνεται με πιθανότητα $1 - p_{2,1} = 1 - p_{3,1}$

$$p_{2,1} = p_{3,1} = \frac{E(N_{I/O}) - 1}{E(N_{I/O})}$$

- Με $E(N_{CPU}) = 5$ quanta, $\mu_1 = 10$ quanta/sec, $E(N_{I/O}) = 3$ κλήσεις, $\mu_2 = 5$ κλήσεις/sec, $\mu_3 = 3$ κλήσεις/sec και αριθμό κλήσεων προς το Q_2 διπλάσιων κατά μέσο όρο από το Q_3 , ζητείται ο μέγιστος ρυθμός γ_{max} εντολών/sec που οδηγεί το σύστημα σε κορεσμό. Για $\gamma = \gamma_{max}/2$ υπολογίστε τον μέσο χρόνο εξυπηρέτησης μιας τυχαίας εντολής

ΠΑΡΑΔΕΙΓΜΑ 2: ΥΠΟΛΟΓΙΣΤΙΚΟ ΣΥΣΤΗΜΑ (3/3)

Με τις παραδοχές του Θεωρήματος **Jackson** έχω το ανοικτό δίκτυο ανεξαρτήτων ουρών M/M/1 Q_1, Q_2, Q_3 με μέσους ρυθμούς εισόδου:

$$\lambda_1 = \gamma + p_{1,1}\lambda_1 + p_{2,1}(\lambda_2 + \lambda_3), \lambda_2 = p_{1,2}\lambda_1, \lambda_3 = p_{1,3}\lambda_1$$

Για τα $p_{1,1}, p_{2,1}$ και $p_{3,1}$ ισχύουν $p_{1,1} = \frac{E(N_{CPU})-1}{E(N_{CPU})}$ και $p_{2,1} = p_{3,1} = \frac{E(N_{I/O})-1}{E(N_{I/O})}$, άρα

$$p_{1,1} = 4/5, p_{2,1} = p_{3,1} = 2/3, p_{1,1} + p_{1,2} + p_{1,3} = 1 \text{ και } p_{1,2} = 2p_{1,3} \text{ άρα } p_{1,3} = 1/15, p_{1,2} = 2/15$$

$$\lambda_2 = 2\lambda_1/15, \lambda_3 = \lambda_1/15, \lambda_1 = \gamma + 4\lambda_1/5 + 2\lambda_1/(3 \times 5) \text{ άρα}$$
$$\lambda_1 = 15\gamma, \lambda_2 = 2\gamma, \lambda_3 = \gamma$$

Για ρυθμούς εξυπηρέτησης μ_i (πελάτες/sec) η χρησιμοποίηση $\rho_i = \lambda_i / \mu_i < 1$ Erlang είναι:

$$\rho_1 = (15/10)\gamma, \rho_2 = (2/5)\gamma, \rho_3 = 0.5\gamma$$

Το στοιχείο συμφόρησης που οδηγεί το σύστημα σε κορεσμό είναι το Q_1 για $\rho_1 = 1.5\gamma_{\max} = 1$ και άρα:

$$\gamma_{\max} = 2/3 \text{ εντολές/sec}$$

Για $\gamma = \gamma_{\max}/2 = 1/3$ εντολές/sec έχουμε:

$$\rho_1 = 1/2 \text{ Erlang}, \rho_2 = 1/2 \text{ Erlang}, \rho_3 = 1/2 \text{ Erlang και}$$

$$E(n_i) = \rho_i / (1 - \rho_i) \Rightarrow E(n_1) = 1, E(n_2) = 4/26, E(n_3) = 5/25$$

$$E(\mathbf{n}) = E(n_1) + E(n_2) + E(n_3) = 1.35 \text{ εντολές}$$

Μέση Απόκριση / Εντολή (**Average Response Time**) από τον τύπο του **Little**: $E(T) = E(\mathbf{n})/\gamma = 4.05 \text{ sec}$