Κατανεμημένα Συστήματα

Εισαγωγή

2019-2020

http://www.cslab.ece.ntua.gr/courses/distrib

Διαδικαστικά

- Διαλέξεις
  - **Τετάρτη 15:15-18:00**, Νέο Κτίριο Ηλεκτρολόγων, Αίθουσα 007
- Διδάσκοντες
  - Καθ. Νεκτάριος Κοζύρης
  - Δρ. Κατερίνα Δόκα (Παλιό Κτ. ΗΜΜΥ 2.1.6)
- Βαθμολογία
  - Εξαμηνιαία εργασία (πριν τα Χριστούγεννα) – 4 μονάδες
  - Εξέταση – 7 μονάδες
- Τελική εξέταση με ανοιχτά βιβλία και σημειώσεις

Βιβλία και Υλικό μαθήματος

- Παρουσιάσεις των διαλέξεων
  - www.cslab.ece.ntua.gr/courses/distrib
- Βιβλίο
  - Κατανεμημένα Συστήματα, G.Coulouris, J. Dollimore, T. Kindberg, G. Blair, Εκδόσεις DA VINCI, κωδικός Ευδόξου: 77112824
- Βοηθητικά βιβλία
  - Κατανεμημένα Συστήματα - Αρχές και Υποδείγματα, Andrew S. Tanenbaum, Maarten Van Steen, Εκδόσεις Κλειδάριθμος,
  - N. Lynch: Distributed Algorithms

Απορίες

- Για οποιαδήποτε απορία ή διευκρίνιση

  Δρ. Κατερίνα Δόκα

  Παλιό Κτίριο Ηλ. 2.1.6

  katerina@cslab.ece.ntua.gr

- Γραφτείτε στη λίστα του μαθήματος!!

  http://lists.cslab.ece.ntua.gr/mailman/listinfo/distrib

Τι είναι ένα κατανεμημένο σύστημα;

Ορισμός

- «Το κατανεμημένο σύστημα είναι μια συλλογή από αυτόνομους υπολογιστές που συνδέονται μεταξύ τους μέσω ενός δικτύου και χρησιμοποιούν ειδικά σχεδιασμένο λογισμικό για την παροχή ενοποιημένων υπολογιστικών υπηρεσιών .» (G. Coulouris)

- «Σε ένα τέτοιο σύστημα οι διεργασίες που εκτελούνται από τους δικτυωμένους υπολογιστές επικοινωνούν μεταξύ τους και συντονίζουν τις κινήσεις τους μόνο μέσω ανταλλαγής μηνυμάτων.» (G. Coulouris)

Κίνητρο

- Διαμοιρασμός πόρων
  - Υλικό
  - Λογισμικό
  - Δεδομένα

Διαμοιρασμός Υλικού

- Υπολογιστική ισχύς (CPU): Κάθε είδους εξυπηρετητής, εξυπηρετητές υπολογισμών σε αρχιτεκτονικές thin client, εφαρμογές τύπου SETI@home
- Περιφερειακά : εκτυπωτές, scanners, επιστημονικά όργανα
- Αποθηκευτικός χώρος: μνήμη (proxy server), δίσκος (file/DB server)
- Μέσο μετάδοσης: Ασύρματα ή ενσύρματα φυσικά δίκτυα

Διαμοιρασμός λογισμικού/δεδομένων

- Ιστοσελίδες, είτε στατικές (π.χ. το υλικό μιας διάλεξης), είτε δυναμικές (π.χ. για την υποστήριξη web-banking)
- Εφαρμογές, π.χ. μια μηχανή αναζήτησης στο Διαδίκτυο
- Βάσεις Δεδομένων, π.χ. Γεωγραφικές ΒΔ για συστήματα εντοπισμού θέσης, μουσική στο iTunes, επεισόδια του Game of Thrones
- Αρχεία, σε έναν file server

Βασικά Χαρακτηριστικά

- Τα βασικά χαρακτηριστικά των κατανεμημένων συστημάτων είναι
  - Ταυτοχρονισμός των στοιχείων που συμμετέχουν
  - Έλλειψη καθολικής εικόνας του χρόνου
  - Απουσία κοινόχρηστης μνήμης
  - Ενδεχόμενο σφάλματος σε κάθε στοιχείο

Γιατί είναι hot τώρα;

- Δίκτυα
- Επεξεργαστές
- Μνήμη
- Αποθηκευτικά μέσα

To Internet - 1969

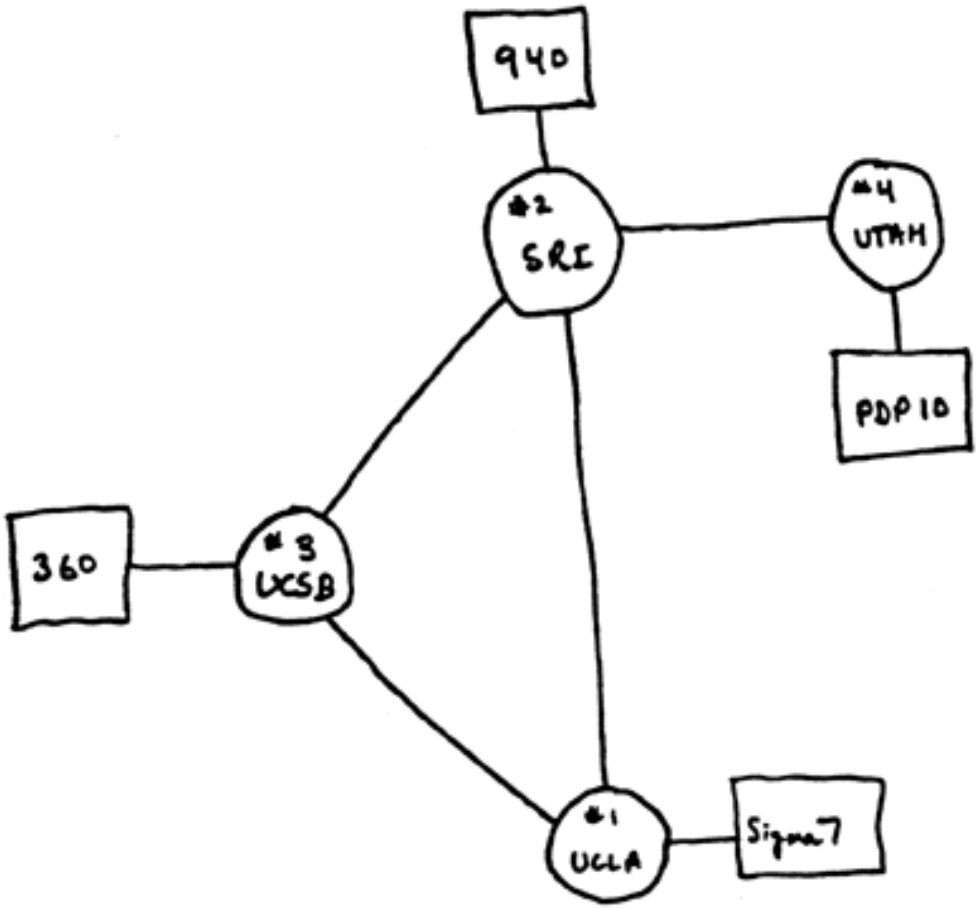

To Internet - σήμερα

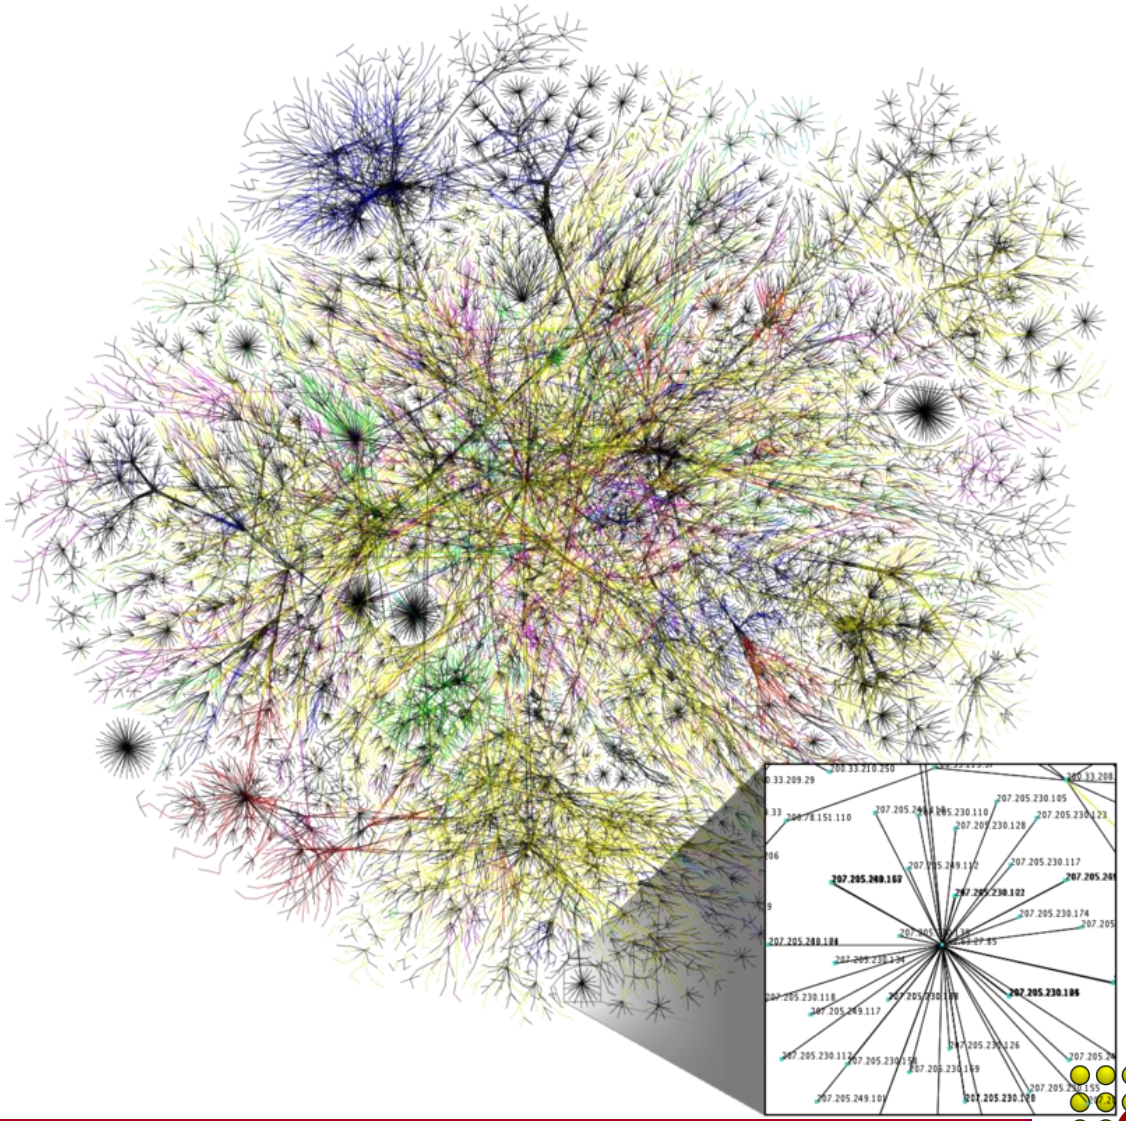

>10^9
nodes

Επεξεργασία

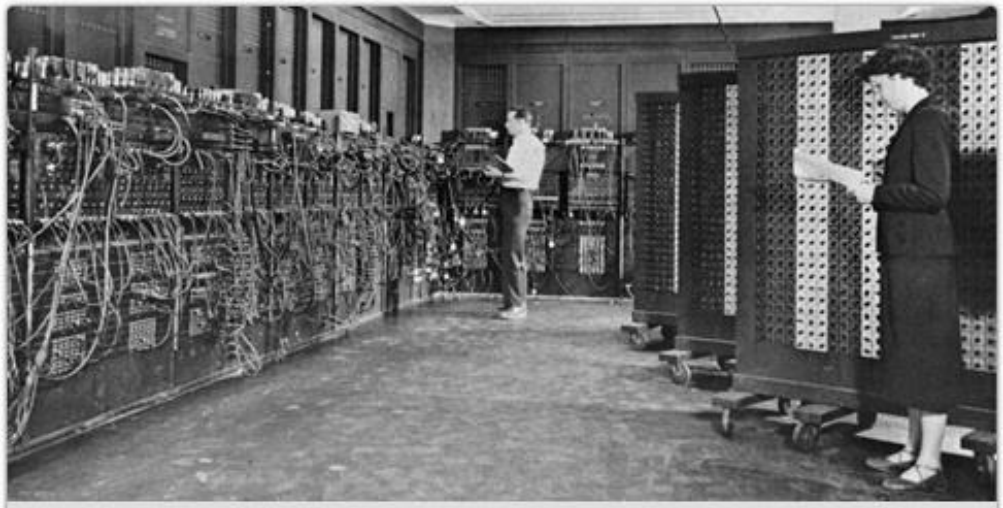

Electronic Numerical Integrator And Computer (ENIAC)

ENIAC: 1 processor

Blue Gene: 250K processors

Μνήμη

- 1977: 256KB, $32000/MB μνήμης
- σήμερα: 8GB, 0.5 cent/MB μνήμης

Αποθηκευτικός χώρος

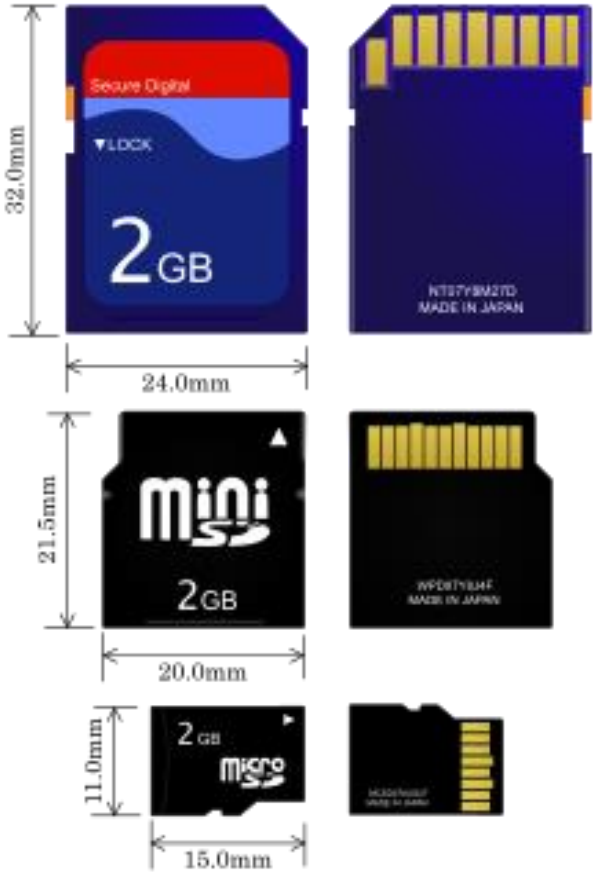

Γιατί τα θέλουμε;

- Αναλογία τιμής/επίδοσης
  - Δεν είναι εύκολη η κλιμάκωση multi-processor
- Κάποιες εφαρμογές είναι κατανεμημένες εκ φύσεως
- Διαδραστική επικοινωνία
  - Messaging, file/photo/video sharing, gaming, telephony
- Απομακρυσμένο περιεχόμενο
  - Web browsing, BitTorrent
- Κινητοί χρήστες
  - Laptops, smart phones, tablets
- Αξιοπιστία
- Σταδιακή αύξηση αναγκών

Trivia

- Movie rendering:
  - Η ταινία Disney Cars 2 χρειαζόταν 11.5 ώρες rendering για κάθε frame
  - Το Monsters University απαιτούσε 29 ώρες για κάθε frame
  - Συνολικός χρόνος: πάνω από 100 εκατομμύρια CPU hours, 5K AMD processors
- Google
  - Εξυπηρετεί πάνω από 40,000 αναζητήσεις το δευτερόλεπτο
  - Δεικτοδοτεί >50 δις σελίδες
  - Χρησιμοποιεί χιλιάδες servers για να επιστρέψει απάντηση σε λιγότερο από δευτερόλεπτο
- Για τη δεικτοδότηση 50 εκατομ. Σελίδων
  - 1999: ένας μήνας
  - 2012: ένα λεπτό

Προκλήσεις

- Είναι δύσκολο να σχεδιάσεις και να υλοποιήσεις ένα κατανεμημένο σύστημα γιατί:
  - Εμπλέκεται μεγάλος αριθμός υπολογιστών
    - Google: 4K
    - Yahoo!: 4K
    - Akamai: 70K
    - Facebook: 60K
  - Οι υπολογιστές αποτυγχάνουν
    - Yahoo!: 50 μηχανήματα αποτυγχάνουν κάθε μέρα (στα 20K)
    - Google: 1 δίσκος αποτυγχάνει ανά 6 ώρες (στους 16K)
    - Lamport: “You know you have a distributed system when the crash of a computer you’ve never heard of stops you from getting the work done”.

Και εμένα τι με νοιάζει;

- Μπορεί να είσαι ο επόμενος Turing Award winner
  - Leslie Lamport, Turing Award 2013
- Μπορείς να πιάσεις δουλειά στην Amazon
  - Ο W. Vogels σε blog post για θέσεις στο group του:

  "What kind of things am I looking for in you? You know your distributed systems theory."
- Τα χρησιμοποιείς καθημερινά και δεν το ξέρεις!

Αρκετά με τη διαφήμιση…

- Παραδείγματα κατανεμημένων συστημάτων
- Πολύ πιο πολύπλοκα από ό,τι φαίνονται από τον web browser…

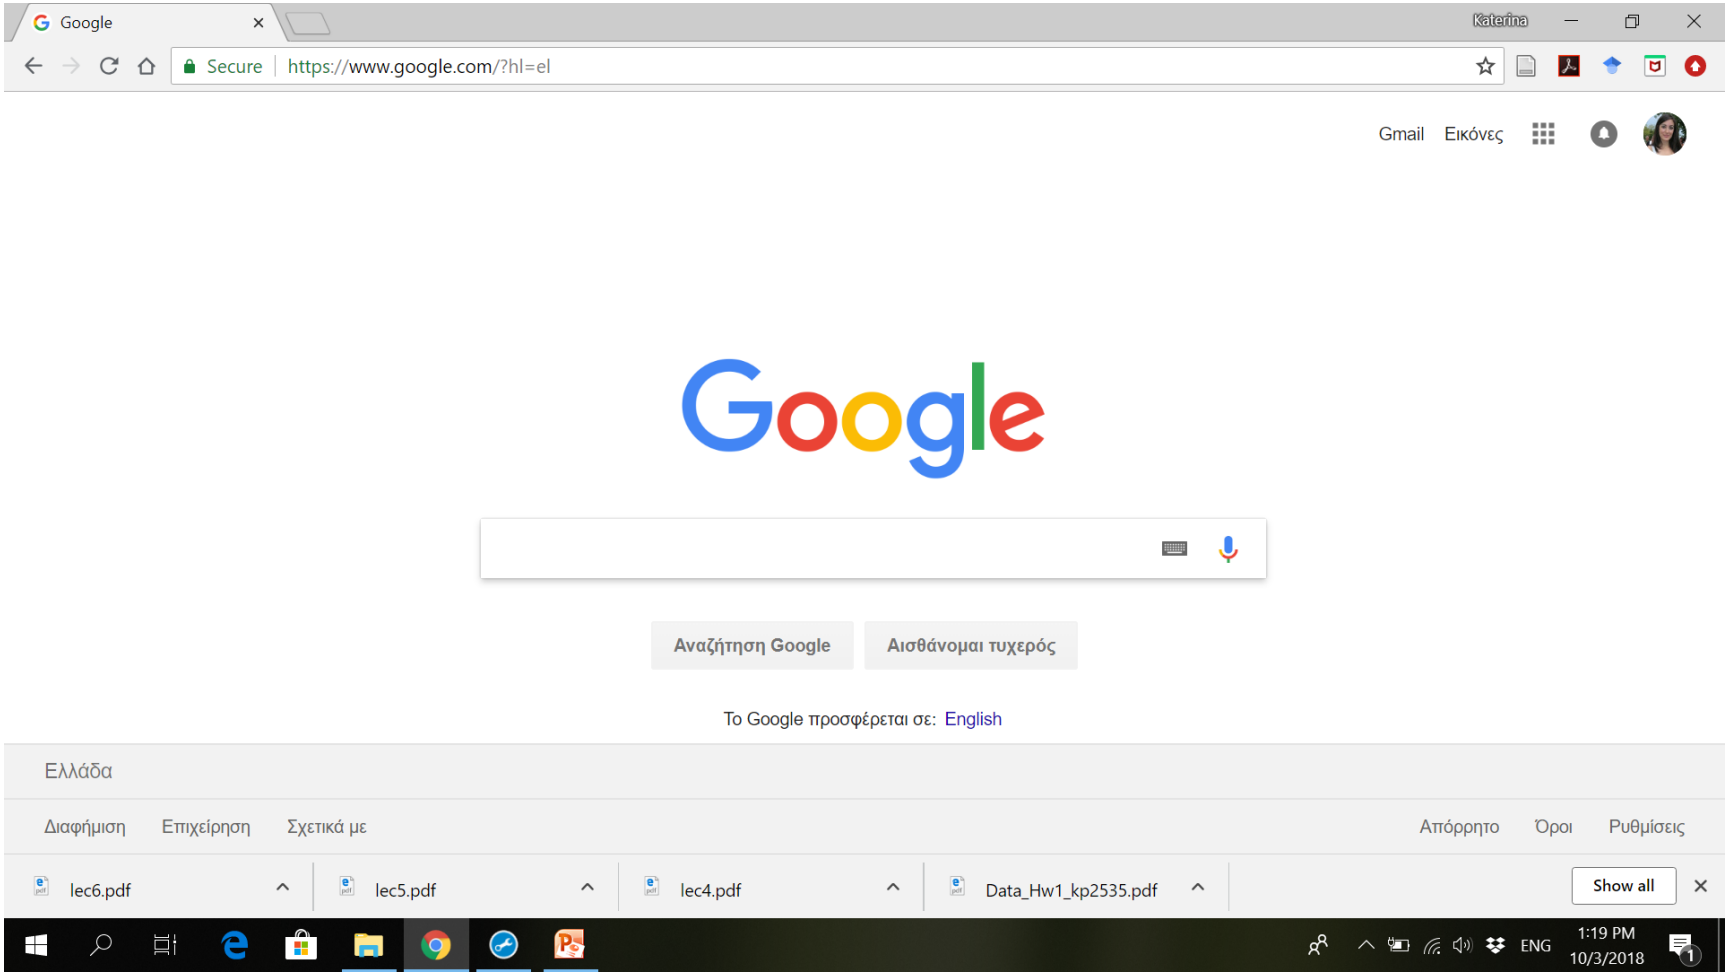
Google
Katerina
Secure
https://www.google.com/?hl=el
Gmail
Εικόνες
Google
Αναζήτηση Google
Αισθάνομαι τυχερός
Το Google προσφέρεται σε: English
Ελλάδα
Διαφήμιση
Επιχείρηση
Σχετικά με
Απόρρητο
Όροι
Ρυθμίσεις
lec6.pdf
lec5.pdf
lec4.pdf
Data_Hw1_kp2535.pdf
Show all
ENG
1:19 PM
10/3/2018

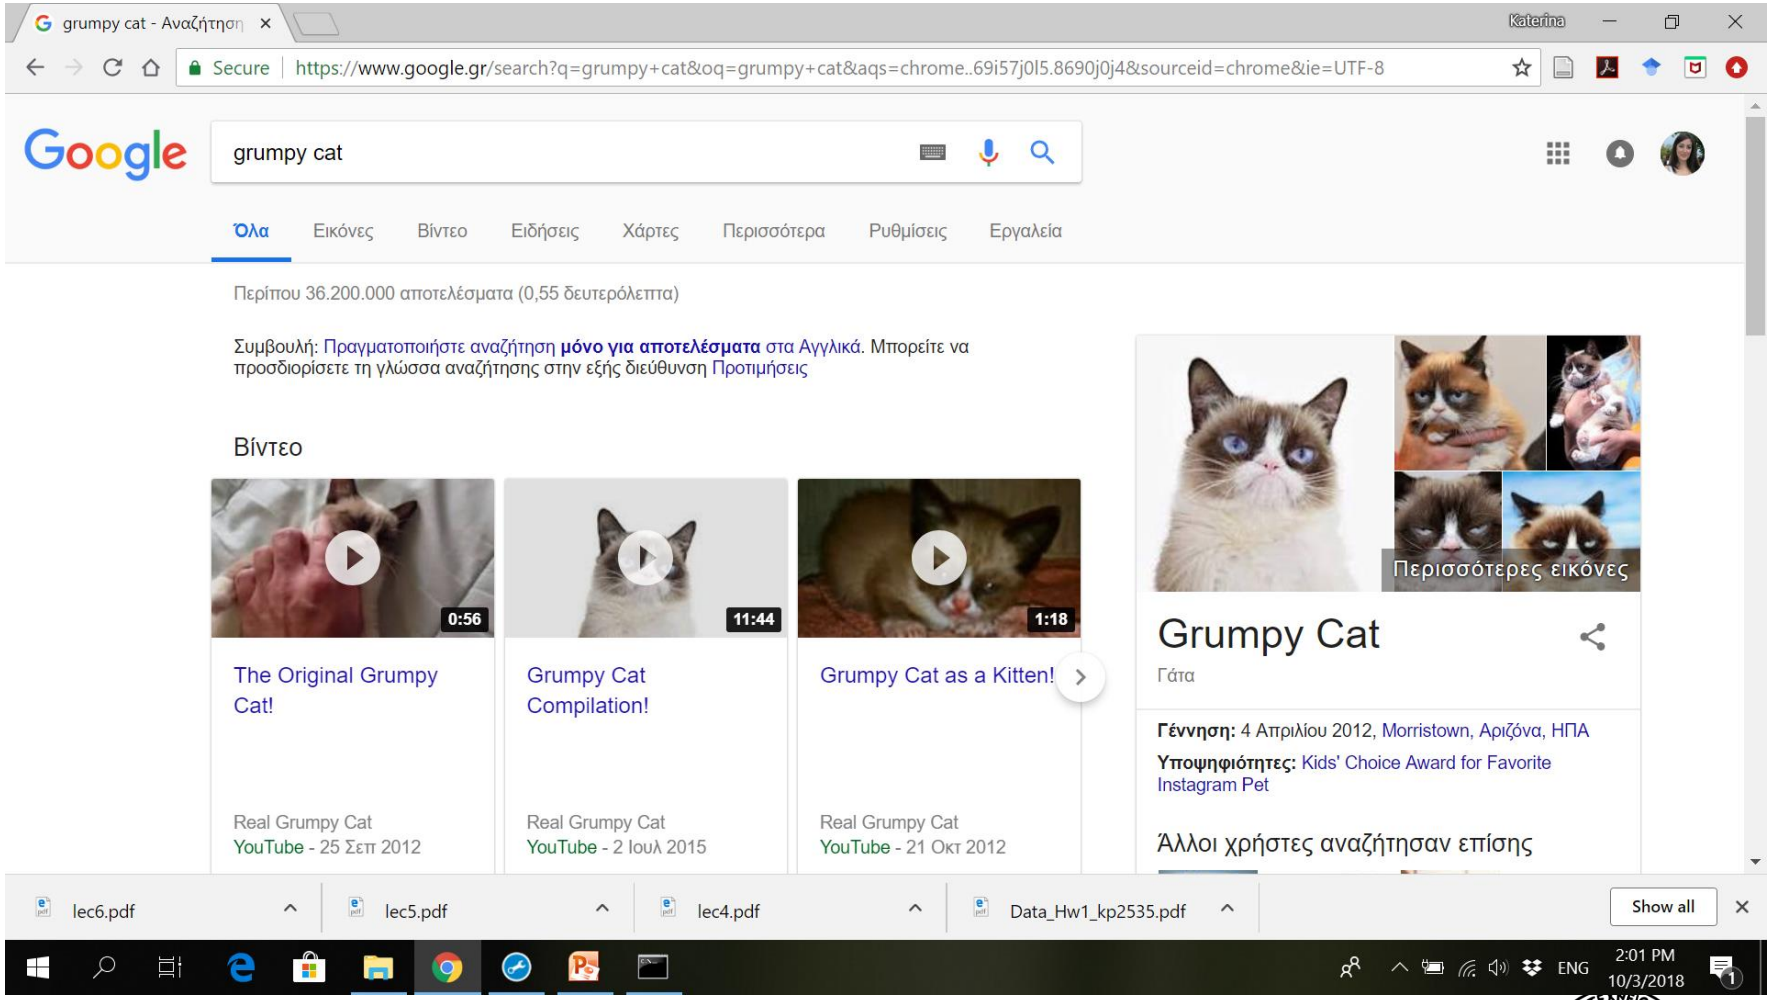

National Technical University of Athens
CSLab

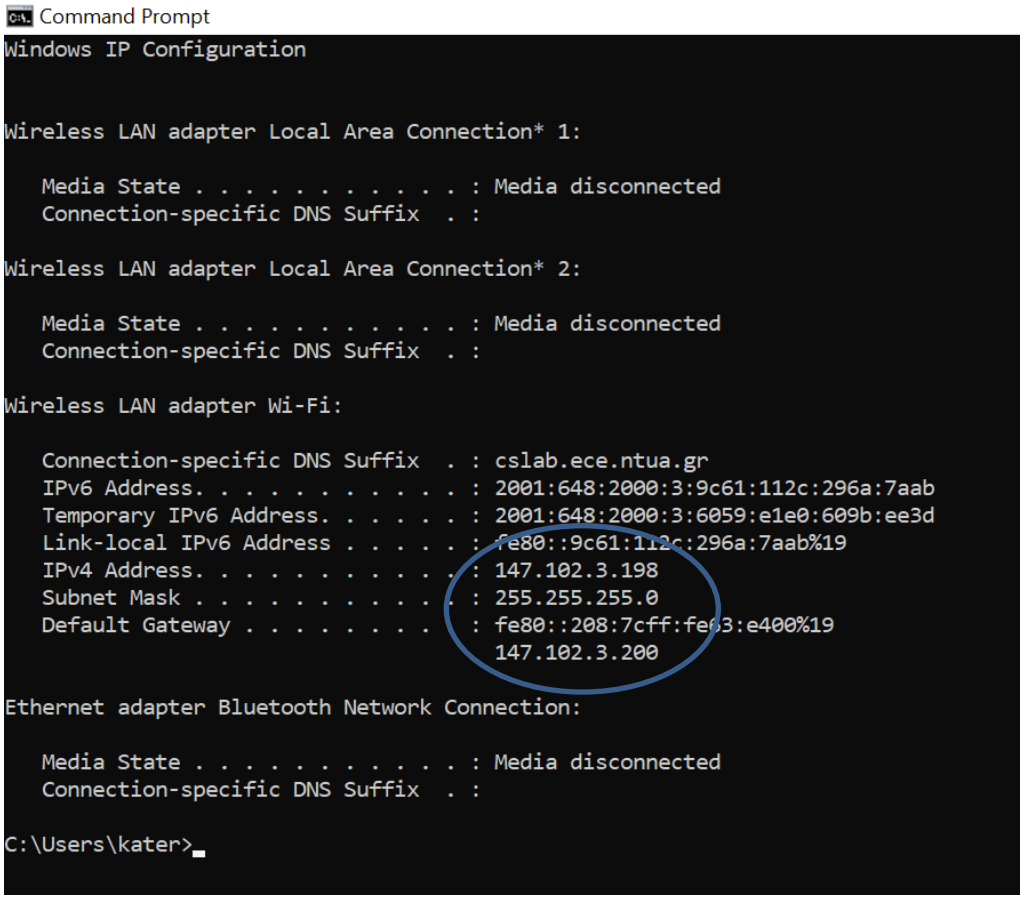
Command Prompt
Windows IP Configuration
Wireless LAN adapter Local Area Connection* 1:
Media State . . . . . : Media disconnected
Connection-specific DNS Suffix . :
Wireless LAN adapter Local Area Connection* 2:
Media State . . . . . : Media disconnected
Connection-specific DNS Suffix . :
Wireless LAN adapter Wi-Fi:
Connection-specific DNS Suffix . : cslab.ece.ntua.gr
IPv6 Address. . . . . : 2001:648:2000:3:9c61:112c:296a:7aab
Temporary IPv6 Address. . . . . : 2001:648:2000:3:6059:e1e0:609b:ee3d
Link-local IPv6 Address . . . . . : fe80::9c61:112c:296a:7aab%19
IPv4 Address. . . . . : 147.102.3.198
Subnet Mask . . . . . : 255.255.255.0
Default Gateway . . . . . : fe80::208:7cff:fe63:e400%19
147.102.3.200
Ethernet adapter Bluetooth Network Connection:
Media State . . . . . : Media disconnected
Connection-specific DNS Suffix . :
C:\Users\kater>

Πώς βρίσκω την IP;

Browser -> browser cache -> router cache -> ISP DNS cache

Αν δεν το βρώ, DNS lookup

NTUA DNS server -> DNS server for .com -> DNS server for google.com -> IP (66.233.169.103)

Όχι μόνο αυτό…

- Σε ποιο google datacenter είναι πιο κοντά το 147.102.3.198;

Ένα Google Datacenter

...κι από μέσα

- Εκατομμύρια cores
- ~20k κόμβοι για ένα tasks

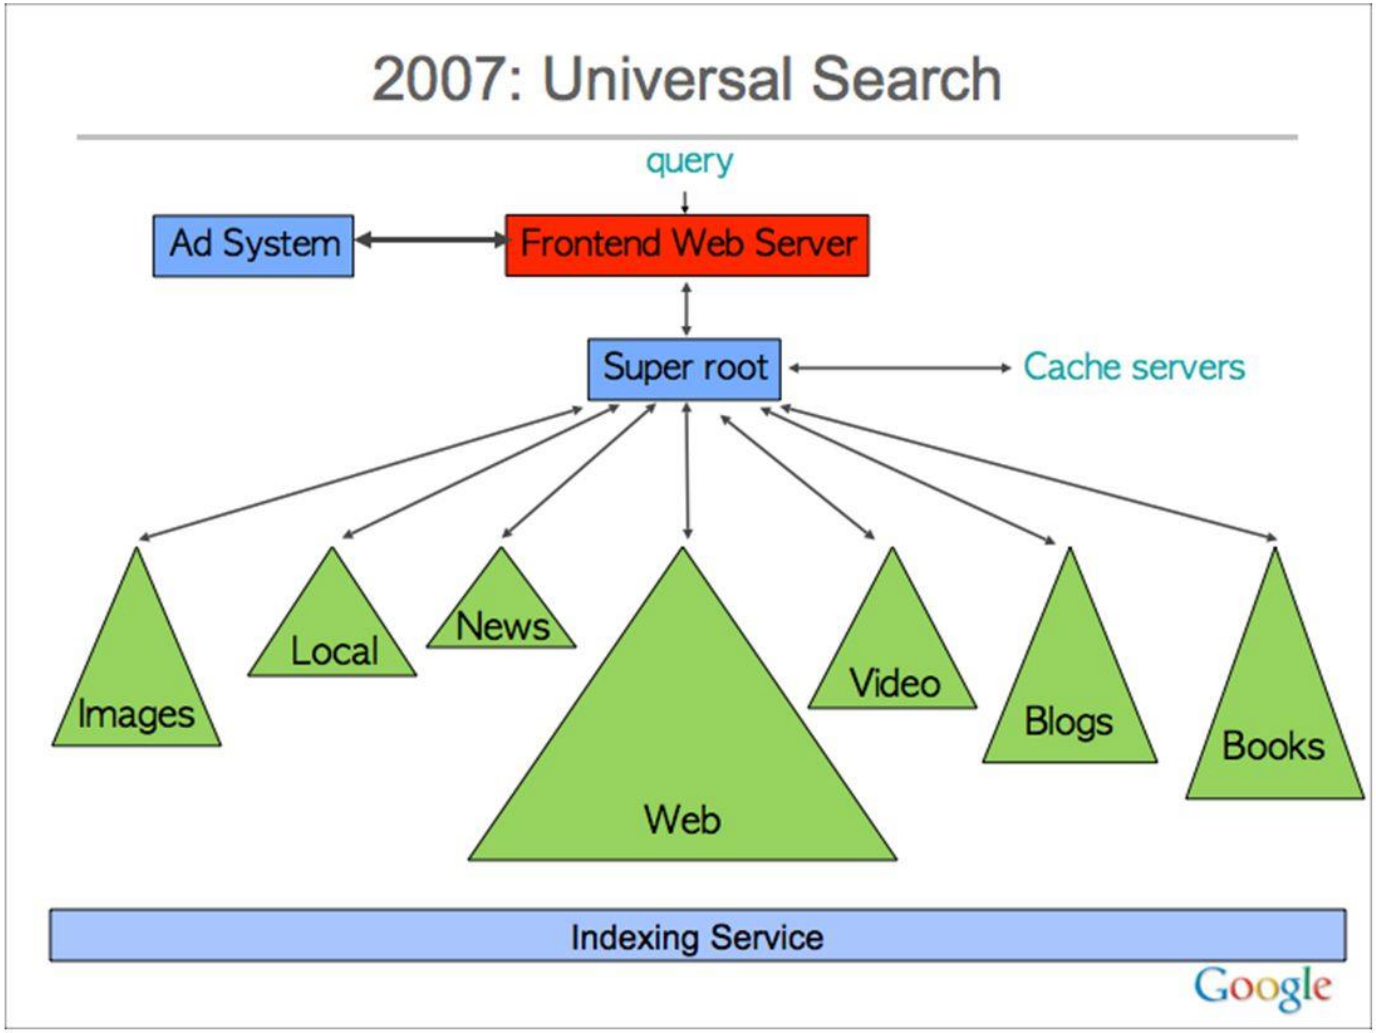

slide from Jeff Dean, Google

Πώς δεικτοδοτείς το διαδίκτυο;

- Πάνω από 1 τρις μοναδικά URLs
- Δισεκατομμύρια μοναδικές ιστοσελίδες
- Εκατομμύρια websites
- 30?? terabytes κειμένου

Τι κάνει η Google;

1. crawling
2. indexing
3. $$$

Google Web Search

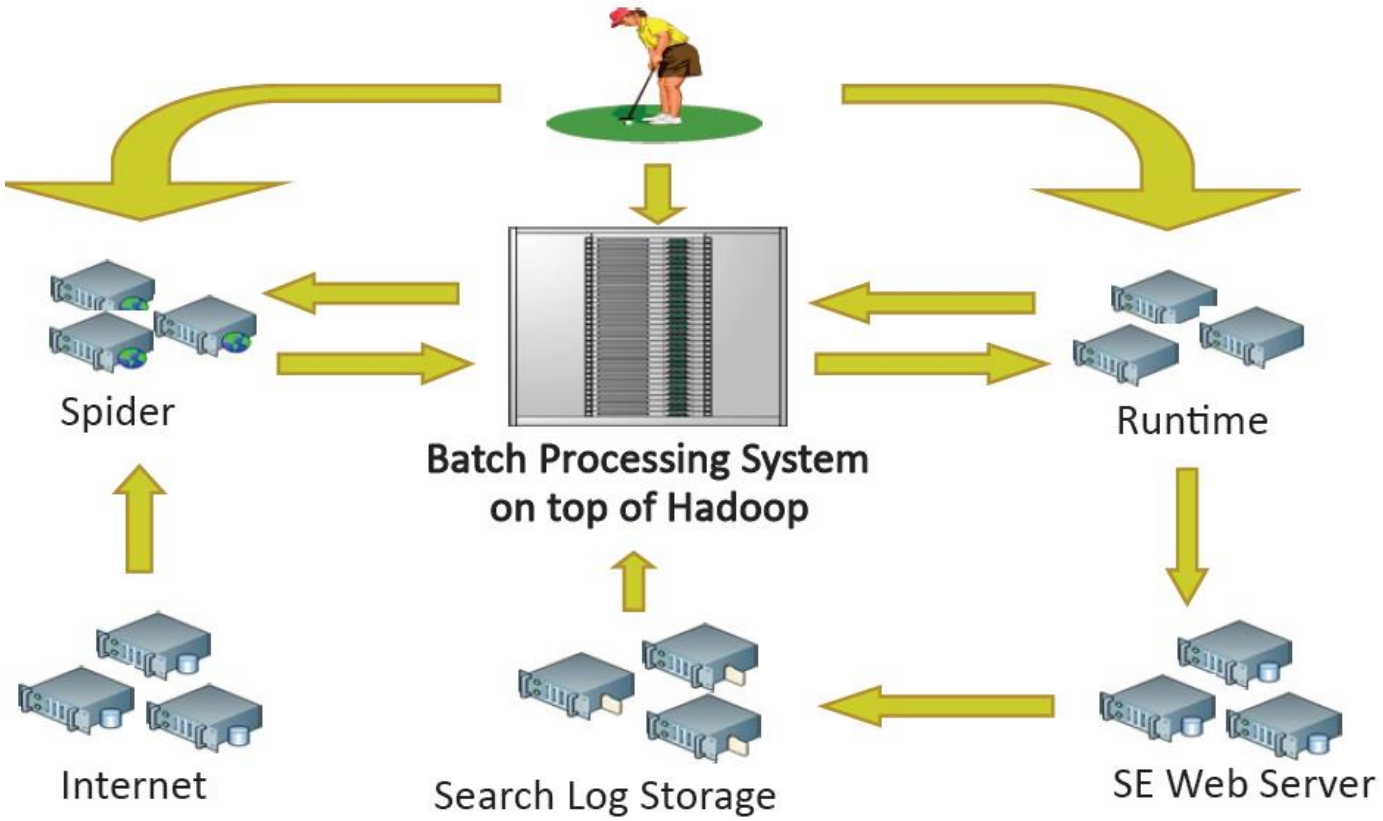

Google File System

BigTable

Chubby

MapReduce

Τελικά

- εκατοντάδες DNS servers
- Δίκτυο routers για να στείλεις πακέτα σε όλον τον κόσμο
- Πρωτόκολλα – πρωτόκολλα – πρωτόκολλα
- Χιλιάδες servers
- ...για να βρεις ένα βίντεο με γάτες σε < 1sec

Τι πρέπει να ξέρω;

- Δίκτυα υπολογιστών
  - Βασικές έννοιες (IP, DNS, TCP, κλπ)
- Λειτουργικά συστήματα
  - Συγχρονισμός διεργασιών
- Προγραμματισμός
  - Εμπειρία με threads, sockets, synchronization primitives, κλπ.

Τι θα μάθω;

- Βασικά θέματα κατανεμημένων συστημάτων
  - Πώς επικοινωνούν οι κόμβοι ενός κατανεμημένου συστήματος;
  - Πώς ελέγχεται η πρόσβαση σε πόρους;
  - Πώς έρχονται σε συμφωνία πολλοί υπολογιστές για έναν κοινό σκοπό;
  - Πώς εντοπίζει ένας κόμβος πού βρίσκονται τα δεδομένα και πώς έχει πρόσβαση σε αυτά;
  - Πώς ανιχνεύονται τα σφάλματα;
  - Πώς εξακολουθεί να δουλεύει το σύστημα μετά από σφάλμα;
  - Με ποιον τρόπο τρέχω μια εργασία κατανεμημένα;

Επικοινωνία

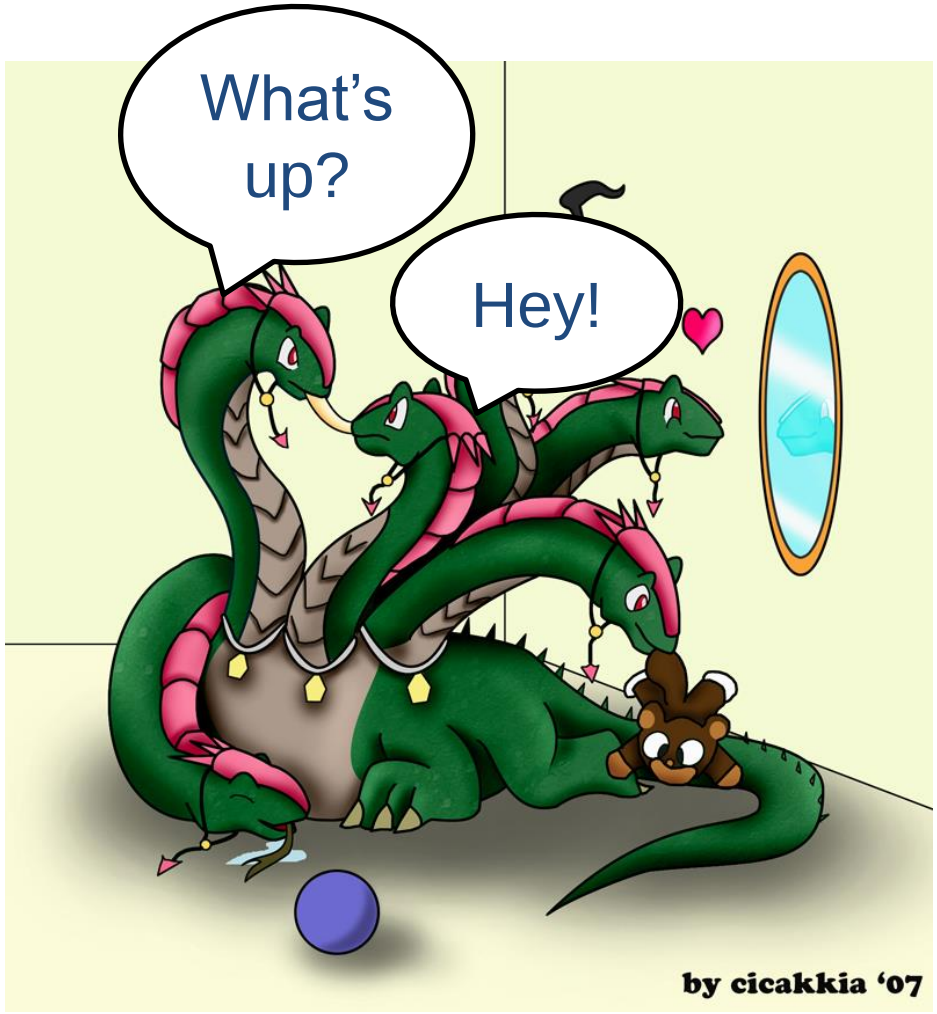

Ταυτοχρονισμός

Ομοφωνία

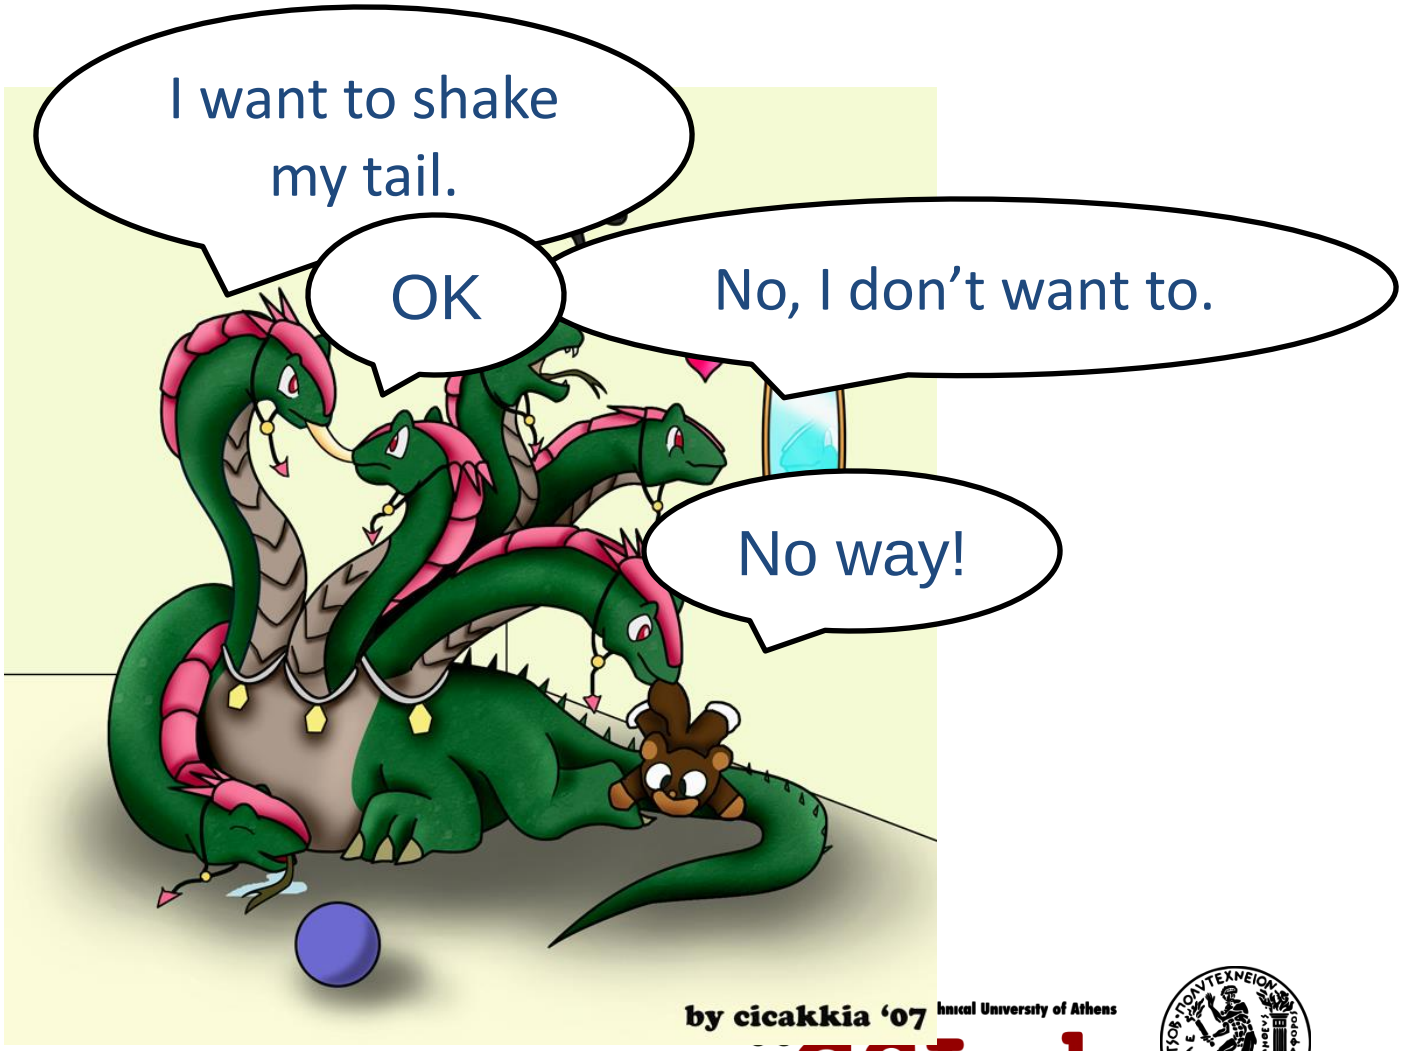
I want to shake my tail.
OK
No, I don't want to.
No way!
by cicakkia '07

Ανίχνευση Σφαλμάτων

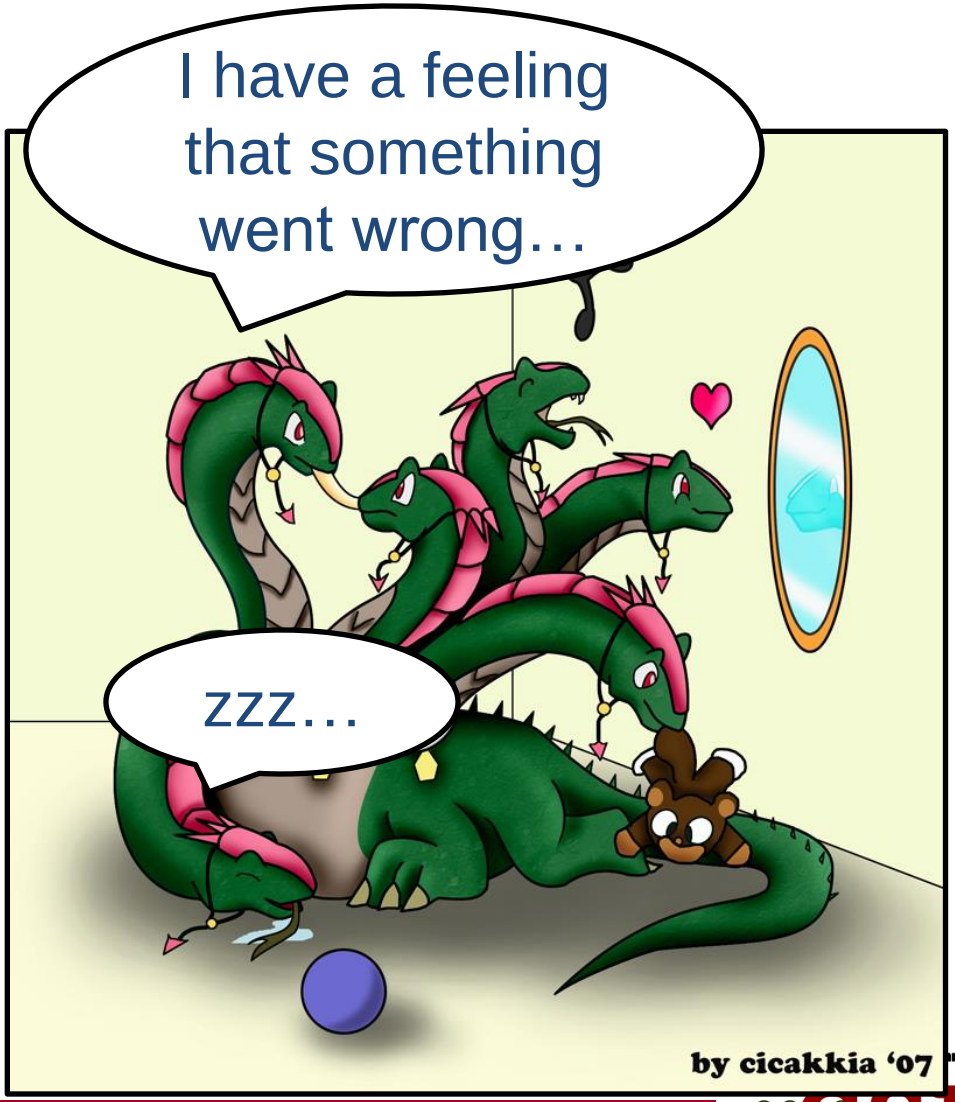

Αποθήκευση δεδομένων

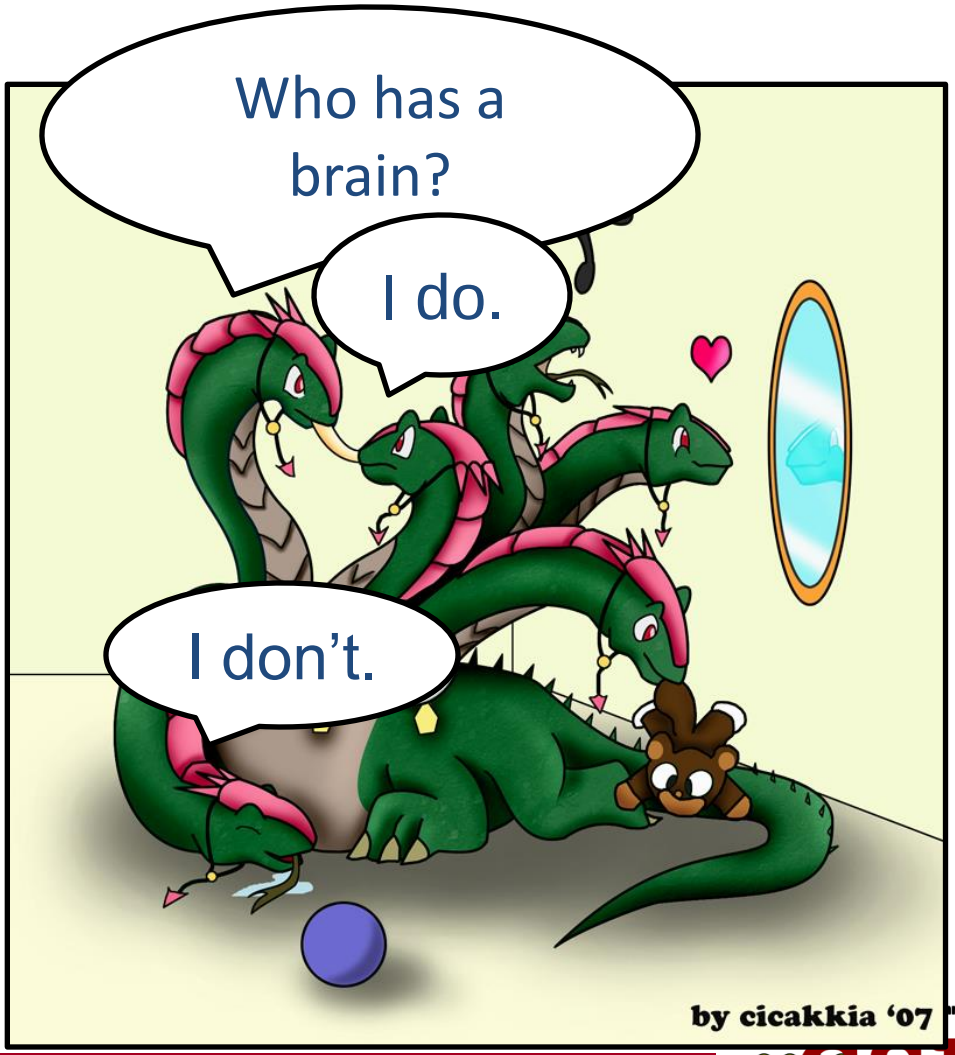

Διαχείριση αντιγράφων

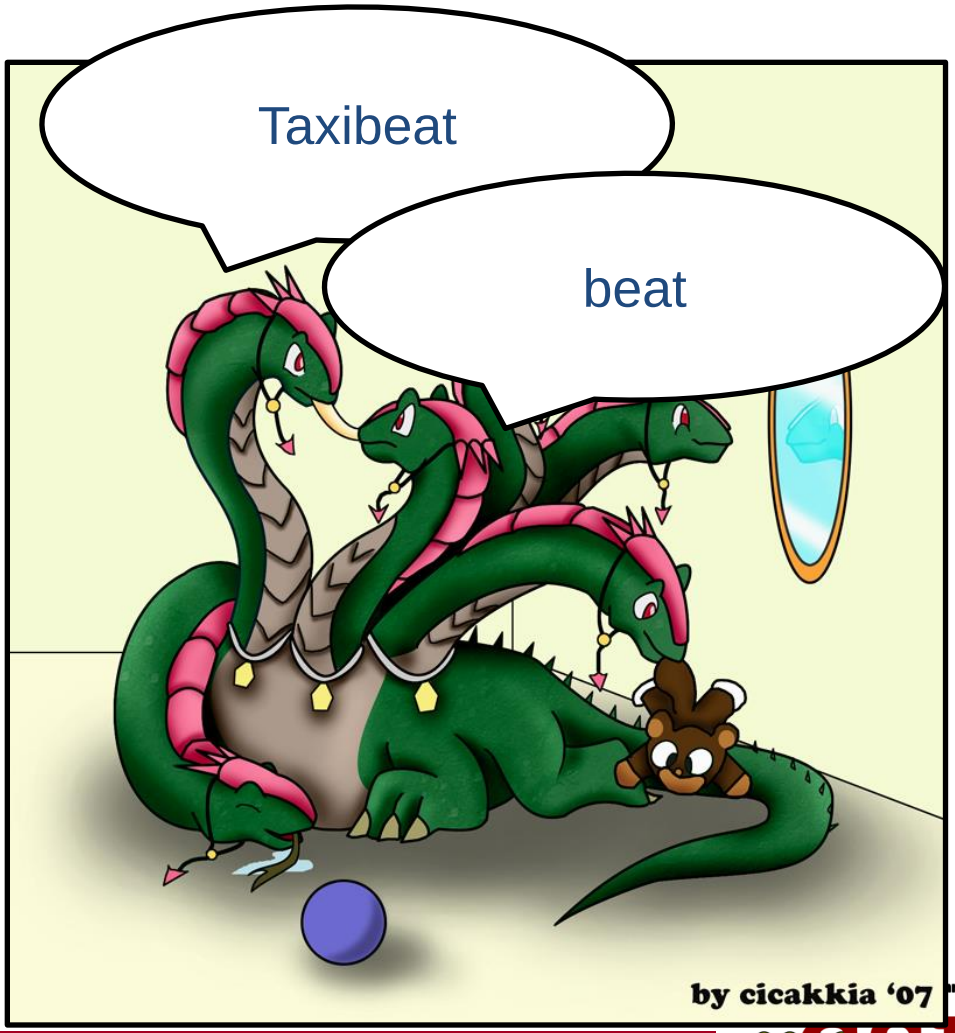

Ύλη Μαθήματος (1)

- Εισαγωγή
  - Αρχιτεκτονικά μοντέλα
- Συγχρονισμός
  - Φυσικά Ρολόγια
  - Λογικά Ρολόγια
  - Συγχρονισμός φυσικών και λογικών ρολογιών
  - Καθολικές Καταστάσεις
- Κατανεμημένος Συντονισμός
  - Ομαδική επικοινωνία
  - Αλγόριθμοι Εκλογής Αρχηγού
  - Αλγόριθμοι Αμοιβαίου Αποκλεισμού
  - Κατανεμημένος αλγόριθμος ομοφωνίας Paxos

Ύλη Μαθήματος (2)

- Δοσοληψίες
  - Ιδιότητες ACID
  - Έλεγχος ταυτοχρονισμού
    - Κλείδωμα 2 φάσεων
    - Διάταξη χρονοσφραγίδων
    - Αισιόδοξος έλεγχος ταυτοχρονισμού

- Κατανεμημένες Δοσοληψίες
  - Ατομικές δοσοληψίες
    - 2 phase commit
    - 3 phase commit
  - Έλεγχος ταυτοχρονισμού κατανεμημένων δοσοληψιών
  - Αλγόριθμοι εντοπισμού αδιεξόδων
  - Ανάνηψη από σφάλματα

Ύλη Μαθήματος (3)

- Αντίγραφα δεδομένων και διαχείρισή τους
  - Το θεώρημα CAP
  - Μοντέλα συνέπειας
  - Πρωτόκολλο gossip

- Δίκτυα Ομότιμων Κόμβων (P2P)
  - Κατηγορίες Δικτύων P2P
  - Κατανεμημένοι Πίνακες Κατακερματισμού (DHT)
  - Βασικές λειτουργίες DHT
  - Παράδειγμα: το σύστημα Chord

Ύλη Μαθήματος (4)

- Κατανεμημένα File Systems
  - Dropbox, Chubby, Google FS, HDFS
- Μοντέλα Κατανεμημένης Επεξεργασίας
  - Προγραμματιστικό Μοντέλο Map-Reduce
  - Προγραμματιστικό μοντέλο Bulk Synchronous Parallel (BSP)

Κεντρικό μοντέλο

- Παραδοσιακό σύστημα time-sharing
- Η επικοινωνία δεν γίνεται μέσω δικτύου
- Δεν κλιμακώνεται εύκολα
  - Όριο στον αριθμό CPUs ανά system bus
  - Μεγάλο contention για κοινόχρηστους πόρους

Μοντέλο πελάτη-εξυπηρετητή

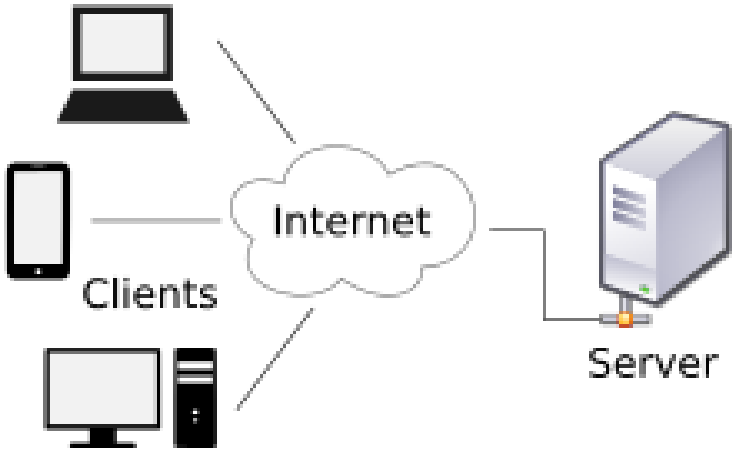

- Ο πελάτης στέλνει αιτήματα στον εξυπηρετητή
- Ο εξυπηρετητής παρέχει πόρους ή υπηρεσίες στους πελάτες
- Οι πελάτες δεν έχουν καμία μεταξύ τους επικοινωνία

+ Εύκολη υλοποίηση και διαχείριση

- Single point of failure, δεν κλιμακώνεται εύκολα

- E-mail, www, ftp, DNS, κλπ.

Thick και thin clients

- Δύο σχολές για τον διαχωρισμό του λογισμικού μεταξύ πελάτη και εξυπηρετητή
- Thin client: Ο πελάτης εκτελεί το λιγότερο δυνατό processing. Το βαρύ processing εκτελείται στον εξυπηρετητή
  - + Λιγότερες απαιτήσεις σε hardware και τεχνολογία
  - + Καθόλου διαχειριστικό κόστος
  - - Latency δικτύου
- Thick client: Το μεγαλύτερο μέρος του processing στον πελάτη
  - +Υψηλές δυνατότητες-χαμηλό κόστος υπολογιστών

Το μοντέλο ομότιμων κόμβων (P2P)

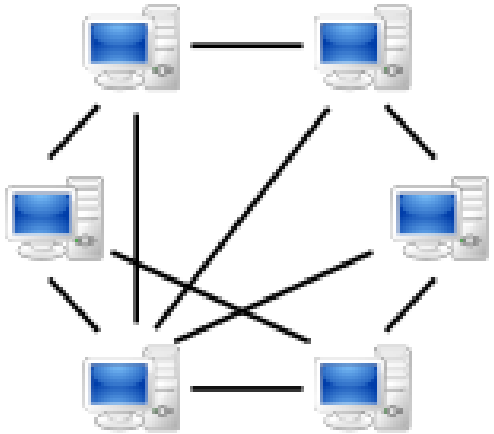

- Όλοι οι κόμβοι είναι ισότιμοι (και πελάτες και εξυπηρετητές)
- Επικοινωνούν μεταξύ τους

+ Robustness, scalability, αυτό-οργάνωση

- Δύσκολη διαχείριση, ασφάλεια

- BitTorrent, skype, κλπ.

Το υβριδικό μοντέλο

- Συνδυασμός client-server και P2P
- Κεντρικός εξυπηρετητής για
  - Εντοπισμό κόμβων
  - Εντοπισμό περιεχομένων
  - Συντονισμό προσπέλασης

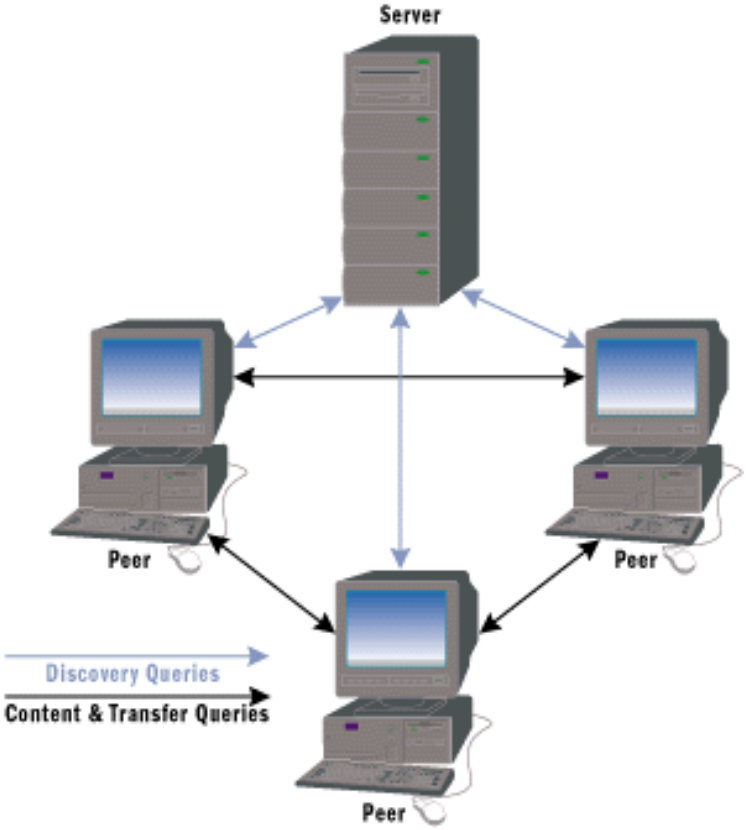

Layered αρχιτεκτονικές

- Πολλά επίπεδα αφαίρεσης
- Κάθε επίπεδο χρησιμοποιεί υπηρεσίες του κατώτερου επιπέδου

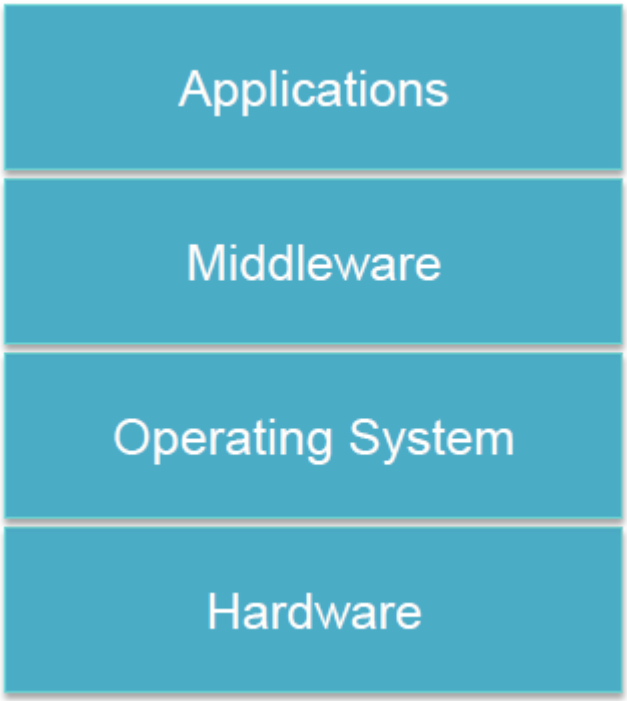

- Κρύβει ετερογένεια
- Παρέχει προγραμματιστικό μοντέλο
- Naming, security, persistence, remote procedures

File system, networking, devices, memory

Tiered αρχιτεκτονικές

- Ο διαχωρισμός των λειτουργιών ενός επιπέδου και η κατανομή τους σε servers/κόμβους

- Κάθε tier
  - Ξεχωριστή δικτυακή υπηρεσία
  - Προσπελάζεται από τα γειτονικά tiers

- Το μοντέλο πελάτη εξυπηρετητή είναι μοντέλο 2-tier
  - Server: Υπεύθυνος για backend υπηρεσίες
  - Client: Υπεύθυνος για διάδραση με χρήστη

Multi-tier παράδειγμα

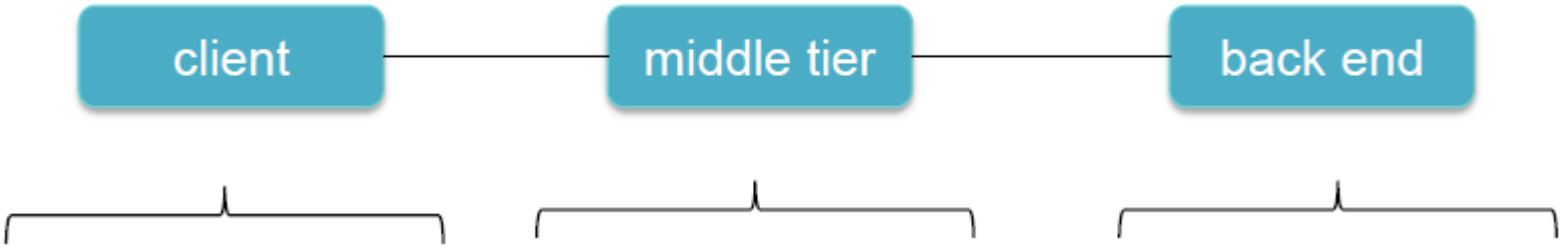

User interface

Queuing requests

Coordinating transactions

Managing connections

Formatting data

Database system

Legacy software

Multi-tier παράδειγμα

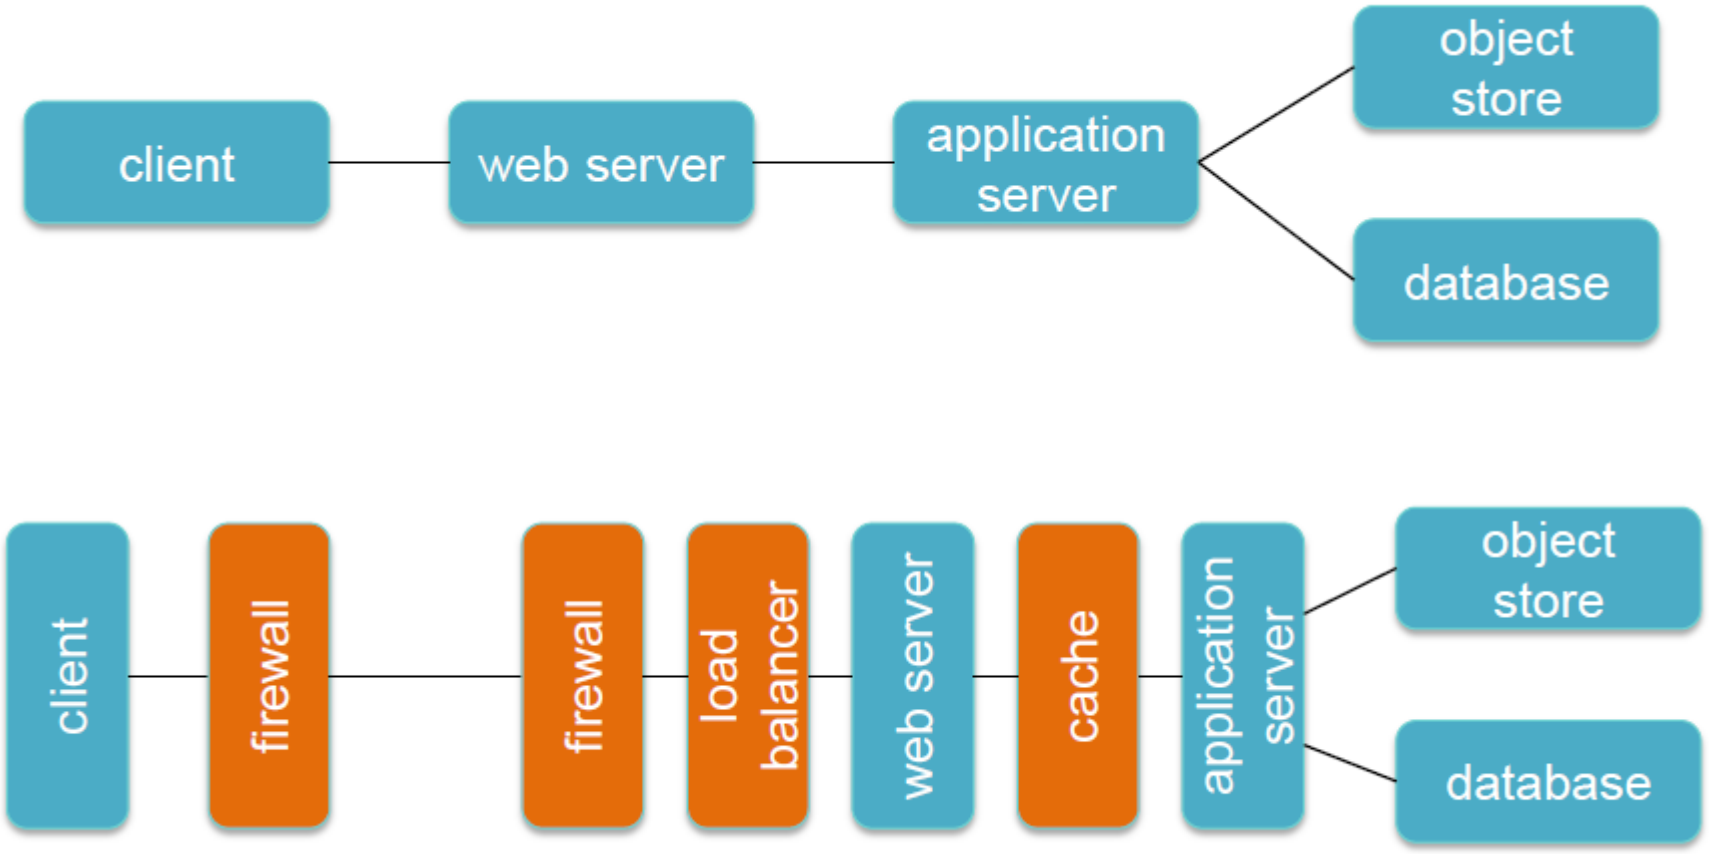

Cloud

Ο πόροι διατίθενται ως υπηρεσίες

- Software as a Service (SaaS)

  Remotely hosted software
  - Salesforce.com, Google Apps, Microsoft Office 365

- Infrastructure as a Service (IaaS)

  Compute + storage + networking
  - Microsoft Azure, Google Compute Engine, Amazon Web Services

- Platform as a Service (PaaS) Deploy & run web applications without setting up the infrastructure
  - Google App Engine, AWS Elastic Beanstalk

- Storage Remote file storage
  - Dropbox, Box, Google Drive, OneDrive, …