Υποδομές Cloud

Διάλεξη 2η

Θωμάς Καμαλάκης

Χαροκόπειο Πανεπιστήμιο Αθηνών

Χειμερινό Εξάμηνο, 2026

Περιεχόμενα

1 Υποδομή
2 Μνήμη
3 CPU
4 GPU
5 GPU wars
6 Διασυνδέσεις
7 Αποθήκευση
8 Δίκτυο

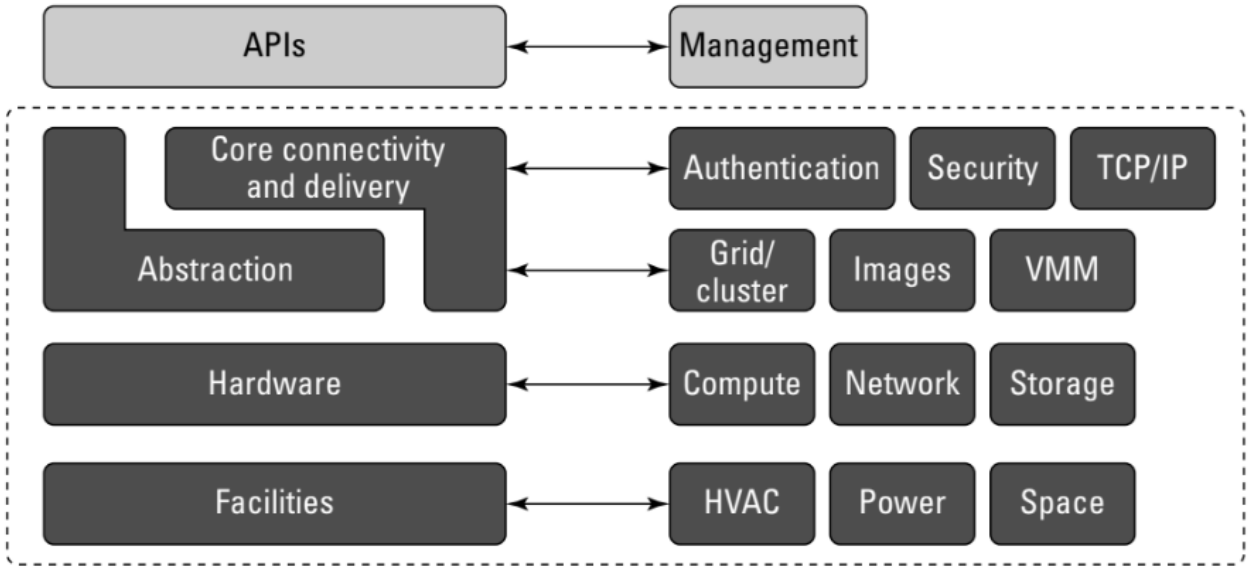
APIs
Management
Core connectivity and delivery
Authentication
Security
TCP/IP
Abstraction
Grid/ cluster
Images
VMM
Hardware
Compute
Network
Storage
Facilities
HVAC
Power
Space

Απαραίτητος Εξοπλισμός

- Φυσικοί Servers
- Μονάδες Αποθήκευσης
- Routers & Switches
- PDUs (Power distribution units)
- Racks
- Cabling
- Cooling

Μνήμη RAM

- **DIMM** (Dual Inline Memory Module): η κάρτα RAM με τα chips DRAM, που μπαίνει στην υποδοχή της μητρικής. Τύπος RAM: συνήθως Double Data Rate (DDR-X).
- Η DDR μεταφέρει δεδομένα στην άνοδο και στην κάθοδο του ρολογιού, δηλαδή δύο φορές ανά κύκλο, διπλασιάζοντας την ταχύτητα σε σχέση με την παλαιότερη SDRAM.
- **DDR5** (2020): το κυρίαρχο πρότυπο το 2026, τόσο σε PCs όσο και σε servers.
- **DDR6**: βρίσκεται σε φάση ανάπτυξης, με αναμενόμενη εμφάνιση γύρω στο 2028–2029, πρώτα σε servers και AI συστήματα.
- Οι servers χρησιμοποιούν *RDIMM* (Registered DIMM): ένα chip (register) αναμεταδίδει τις εντολές στα chips DRAM. Έτσι η CPU οδηγεί μία μόνο είσοδο ανά DIMM και μπορούν να συνδεθούν περισσότερα DIMM ανά κανάλι. Συνδυάζεται με *ECC*, που διορθώνει σφάλματα bit.

Μνήμη RAM

- Χωρητικότητα: δεκάδες GB σε ένα PC, αλλά έως και αρκετά TB ανά server.
- Ταχύτητα: μετριέται σε MT/s (εκατομμύρια μεταφορές ανά δευτερόλεπτο). Λόγω DDR, η DDR5-6400 έχει ρολόι 3200 MHz αλλά 6400 MT/s.
  - DDR4: έως 3200 MT/s.
  - DDR5 σε PCs: 5600–6400 MT/s, και μεγαλύτερες ταχύτητες για gaming.
  - DDR5 σε servers (2026): 6400 MT/s, έως 8000 MT/s στη νέα γενιά (π.χ. AMD EPYC «Venice»).
  - **MRDIMM** (Multiplexed Rank DIMM): συνδυάζει δύο ranks ώστε να διπλασιάζει την ταχύτητα. Η 2η γενιά φτάνει τα 12800 MT/s.

Μνήμη RAM

- Τα κανάλια μνήμης (memory channels) στη RAM αναφέρονται στον τρόπο με τον οποίο η RAM επικοινωνεί με τον επεξεργαστή (CPU) μέσω του ελεγκτή μνήμης.
- Ένα κανάλι είναι ο δρόμος μέσω του οποίου μεταφέρονται τα δεδομένα από τη RAM στον επεξεργαστή, και ο αριθμός των καναλιών επηρεάζει το πόσα δεδομένα μπορούν να μεταφερθούν ταυτόχρονα.
- PCs: συνήθως 2 κανάλια (dual channel). Servers: 12 κανάλια ανά CPU, και 16 στη γενιά του 2026 (AMD EPYC «Venice»: $\sim$1.6 TB/s ανά socket).

Κανάλια Μνήμης

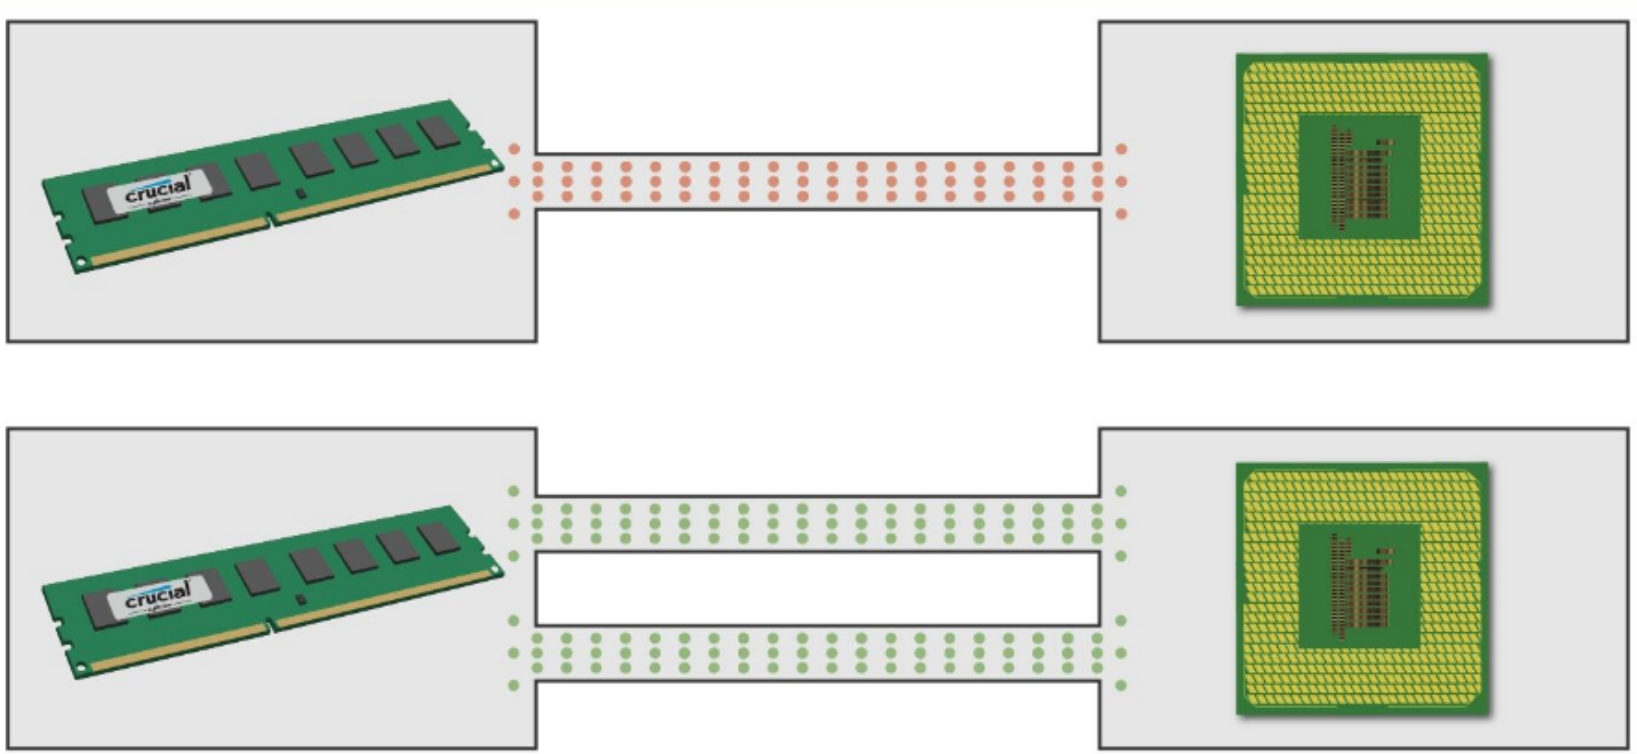

Μνήμη στην εποχή του AI (2026)

- **HBM vs DDR**: η HBM (στις GPUs) δίνει $\sim 10\times$ μεγαλύτερο εύρος ζώνης από ένα CPU socket, αλλά με πολύ μικρότερη χωρητικότητα και πολύ υψηλότερο κόστος ανά GB.
- **LPDDR5X σε servers**: οι CPUs Grace/Vera της NVIDIA χρησιμοποιούν μνήμη τύπου κινητού για χαμηλή κατανάλωση.
- **CXL** (Compute Express Link): επέκταση μνήμης μέσω PCIe. Ένας server μπορεί να «δανειστεί» επιπλέον RAM από εξωτερικές κάρτες ή κοινόχρηστα memory pools.
- **Έλλειψη μνήμης 2026**: οι κατασκευαστές (SK Hynix, Samsung, Micron) στρέφουν την παραγωγή σε HBM για τα AI chips, με αποτέλεσμα να υπάρχει έλλειψη συμβατικής DRAM.
  - Οι τιμές συμβολαίων DRAM σχεδόν διπλασιάστηκαν το Q1 2026 ($\sim$+90%) και αυξήθηκαν ξανά κατά $\sim$60% το Q2 (TrendForce).
  - Το κόστος των servers, των PCs και του cloud αυξάνεται αντίστοιχα.

Η τιμή της RAM στον χρόνο

Corsair Vengeance LPX 16GB (2×8GB) DDR4-3200: τιμή στο Amazon ($)

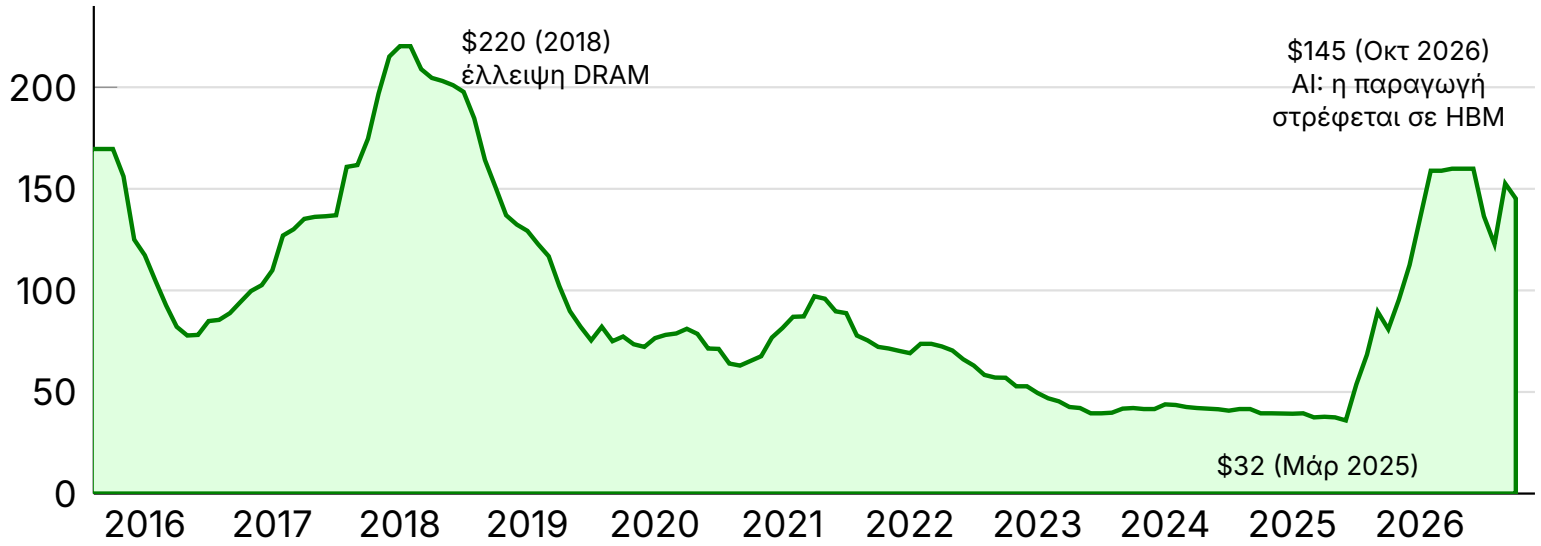

Μηνιαία διάμεσος τιμής Amazon (Corsair CMK16GX4M2B3200C16). Πηγή: camelcamelcamel.

- Η τιμή της ίδιας ακριβώς μνήμης ακολουθεί τους κύκλους της αγοράς DRAM: έλλειψη το 2017–18, υπερπροσφορά έως το 2025.
- Από τα μέσα του 2025 η τιμή υπερτετραπλασιάστηκε ($32 → $145–160): η παραγωγή μεταφέρεται σε HBM για τις AI GPUs και η DDR4 αποσύρεται σταδιακά.

CPU

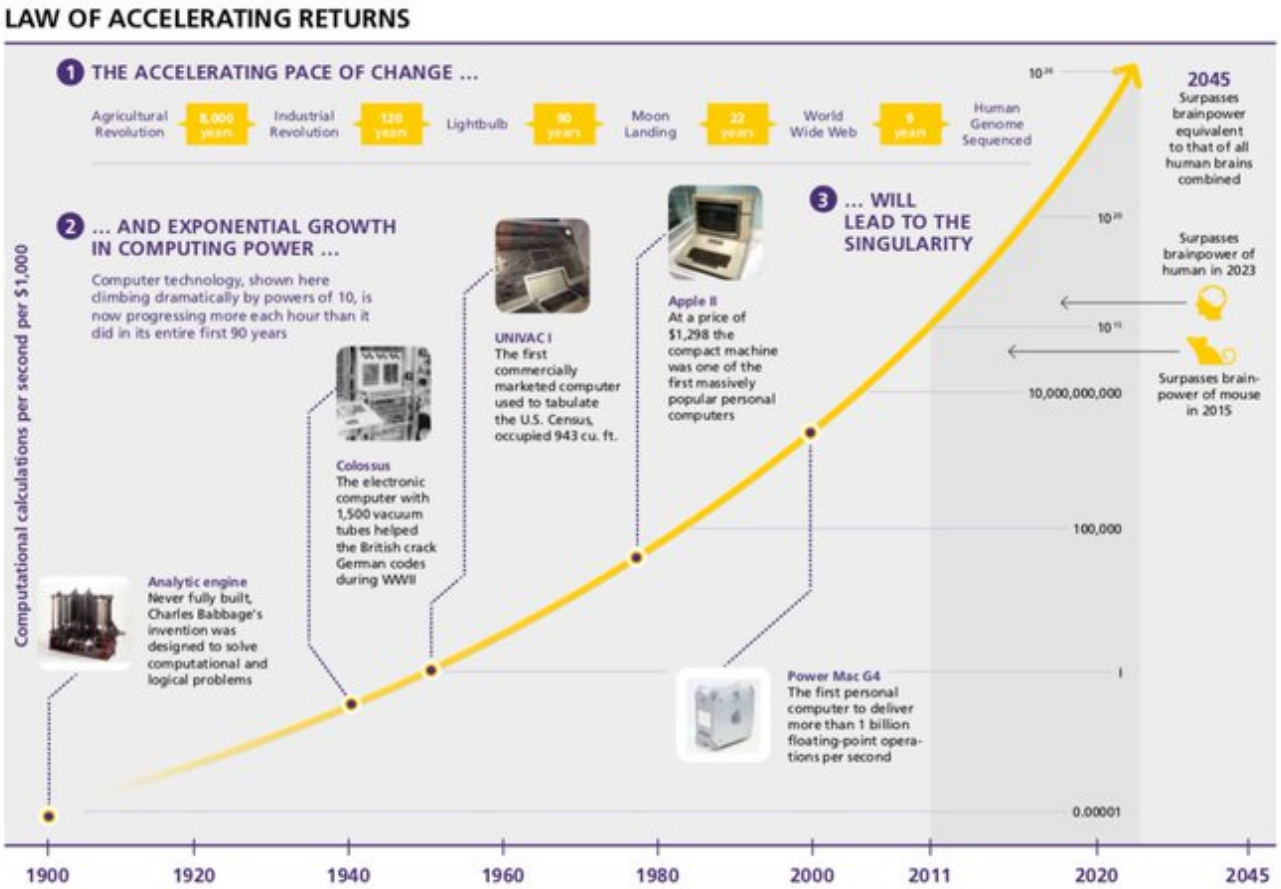

Figure 12: Ray Kurzweil's Law of Accelerating Returns depicts the exponential growth of computer processing power and technology innovations throughout history, and anticipates computers will exceed human intelligence in the future; **Source:** TIME / Wikipedia

source dhl via @mikequindazzi

Ο νόμος του Moore

- Ο αριθμός των τρανζίστορ μέσα σε μία CPU διπλασιάζεται κάθε δύο χρόνια.

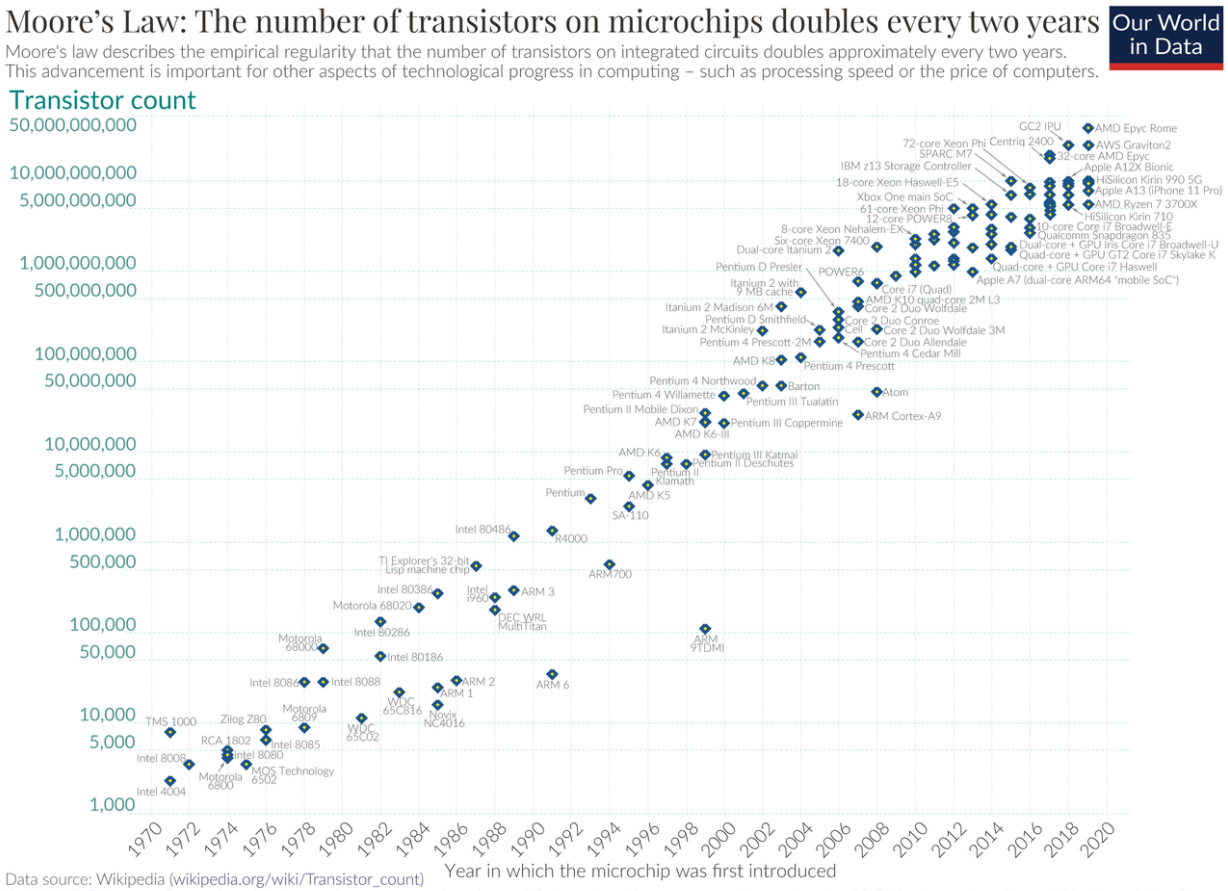

Προδιαγραφές CPU

- Αριθμός Πυρήνων (Cores): οι ανεξάρτητες μονάδες επεξεργασίας μέσα στην CPU. Ο αριθμός των πυρήνων καθορίζει πόσα νήματα (threads) μπορεί να επεξεργαστεί η CPU ταυτόχρονα.
- Συχνότητα Ρολογιού (Clock Speed): αναφέρεται στην ταχύτητα με την οποία η CPU εκτελεί εντολές. Αντιστοιχεί σε πόσες εντολές μπορεί να εκτελέσει ανά δευτερόλεπτο.
- Αρχιτεκτονική: x86-64 ή ARM.

Συχνότητα Ρολογιού

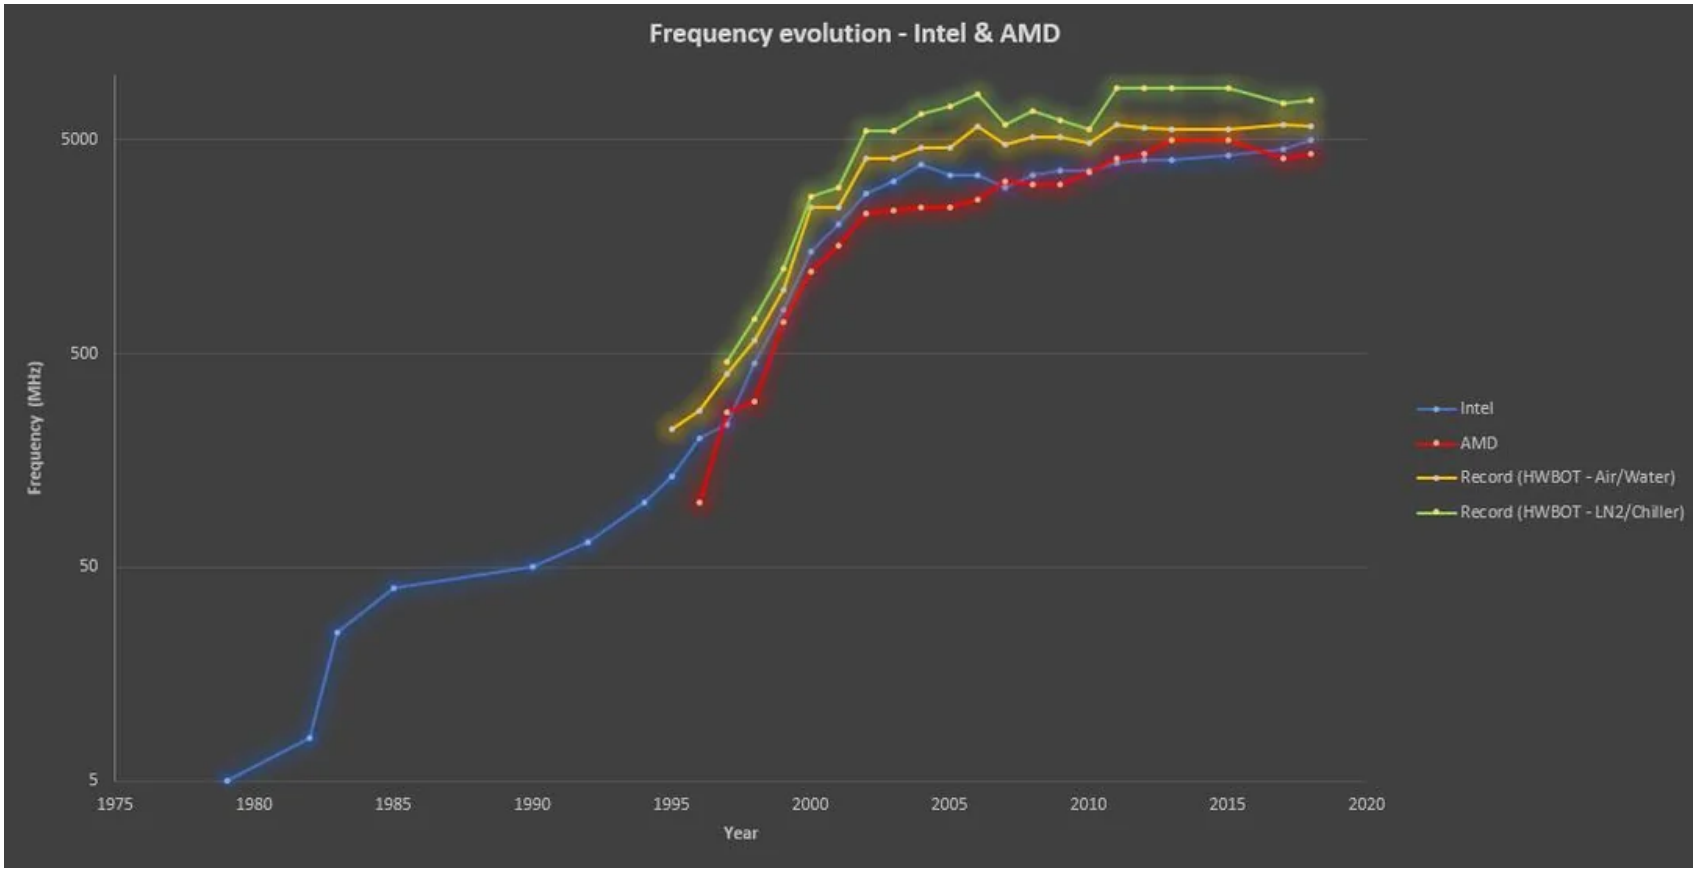

Προδιαγραφές CPU

- Μνήμη cache: πολύ γρήγορη, προσωρινή μνήμη που βρίσκεται εντός της CPU και χρησιμοποιείται για την αποθήκευση συχνά χρησιμοποιούμενων δεδομένων ή εντολών.
- L1: Η ταχύτερη και μικρότερη μνήμη, που βρίσκεται πολύ κοντά στον πυρήνα.
- L2: Ελαφρώς πιο αργή, αλλά μεγαλύτερη από την L1.
- L3: Ακόμα μεγαλύτερη και πιο αργή από τις L1 και L2, αλλά είναι κοινή μεταξύ των πυρήνων.

Ιεραρχία μνήμης cache: L1, L2, L3

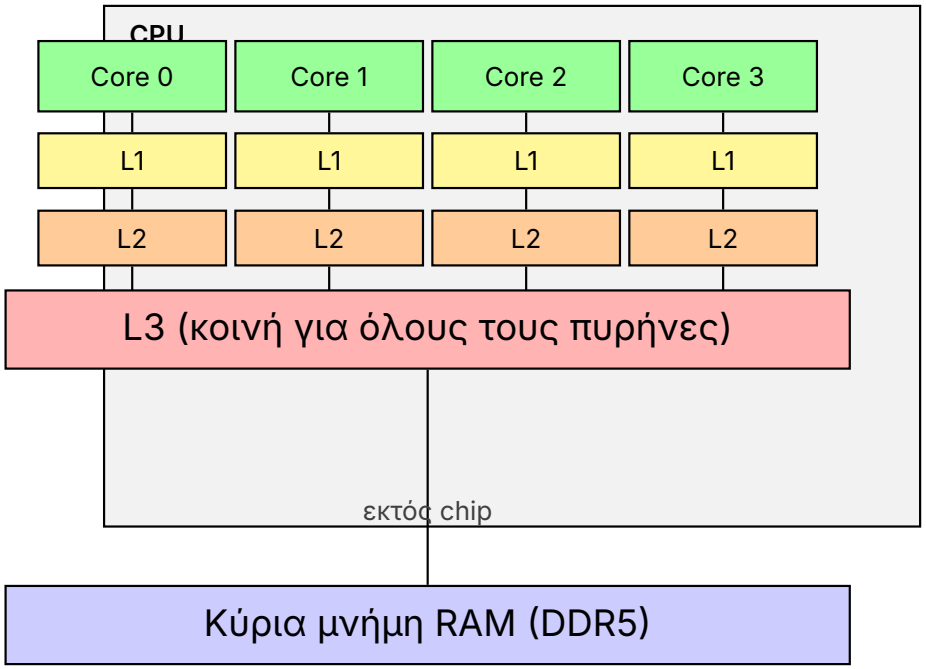

	Μέγεθος	Latency
L1	32–64 KB	∼1 ns
L2	1–2 MB	∼4 ns
L3	32 MB–1 GB	∼15–40 ns
RAM	GB–TB	∼80–100 ns

- Κάθε πυρήνας έχει δική του L1 και L2· η L3 μοιράζεται. Όσο πιο κοντά στον πυρήνα, τόσο πιο γρήγορη και μικρότερη η μνήμη.
- Αν το δεδομένο δεν βρεθεί (*cache miss*), η CPU κατεβαίνει στο επόμενο επίπεδο και τελικά στη RAM.

Προδιαγραφές CPU

- Hyper-threading (Intel) ή Simultaneous Multithreading (AMD)
- Μια τεχνολογία που επιτρέπει σε κάθε πυρήνα της CPU να επεξεργάζεται δύο νήματα ταυτόχρονα, βελτιώνοντας την αποδοτικότητα της CPU σε εφαρμογές που μπορούν να εκμεταλλευτούν την πολυδιεργασία.
- το pipeline χωρίζει την εκτέλεση μιας εντολής σε διάφορα στάδια, επιτρέποντας σε κάθε στάδιο να επεξεργάζεται μία εντολή ταυτόχρονα με άλλα στάδια που επεξεργάζονται άλλες εντολές. Έτσι, πολλές εντολές μπορούν να εκτελούνται παράλληλα, αυξάνοντας την αποδοτικότητα.

CPU: State-of-the-art (2026)

CPU	Εταιρεία	Αρχιτεκτονική	Πυρήνες	Κατασκευή
Xeon 6 (Granite Rapids)	Intel	x86, P-cores	έως 128	Intel 3
Xeon 6+ (Clearwater Forest)	Intel	x86, E-cores	έως 288	Intel 18A
EPYC 9006 (Venice)	AMD	x86, Zen 6 / 6c	έως 96 / 256	TSMC 2nm
Vera	NVIDIA	Arm, Olympus	88	TSMC 3nm

- **P-core** (Performance): μεγάλος, ισχυρός πυρήνας με υψηλή συχνότητα και SMT, για μέγιστη απόδοση ανά νήμα. **E-core** (Efficient): μικρότερος και απλούστερος πυρήνας, που καταλαμβάνει λιγότερο χώρο και καταναλώνει λιγότερο, ώστε να χωράνε πολλοί σε ένα chip (π.χ. 288 στο Clearwater Forest). Η AMD ακολουθεί την ίδια ιδέα με τους Zen 6c.
- AMD Venice: έως 1 GB L3 cache, 16 κανάλια μνήμης, ∼1.6 TB/s εύρος ζώνης ανά socket (έναντι 576 GB/s της προηγούμενης γενιάς).
- NVIDIA Vera: μνήμη LPDDR5X με έως 1.2 TB/s, σχεδιασμένη για AI servers δίπλα στις GPUs. Διαθέσιμη από το β′ εξάμηνο του 2026.
- Τάση: περισσότεροι πυρήνες αντί για υψηλότερη συχνότητα· η Arm κερδίζει έδαφος στα data centers (NVIDIA Vera, AWS Graviton). Η Intel Diamond Rapids (P-cores) δεν έχει κυκλοφορήσει ακόμη.

Λιθογραφία

- Η λιθογραφία (ή κόμβος κατασκευής, process node) δηλώνει τη γενιά της τεχνολογίας κατασκευής του chip και εκφράζεται σε νανόμετρα (nm). Παλαιότερα ο αριθμός αντιστοιχούσε στο μέγεθος των transistor, ενώ σήμερα είναι κυρίως εμπορική ονομασία. Όσο μικρότερο το μέγεθος, τόσο περισσότερα transistor μπορούν να τοποθετηθούν σε μια CPU, προσφέροντας αυξημένη απόδοση και χαμηλότερη κατανάλωση ενέργειας.
- Οι σύγχρονες CPUs είναι κατασκευασμένες με τεχνολογίες 7nm, 5nm, ή ακόμη και μικρότερες.

Λιθογραφία: State-of-the-art (2026)

- Τα chips τυπώνονται πάνω στο πυρίτιο με φως, μέσω μασκών. Όσο μικρότερο το μήκος κύματος του φωτός, τόσο μικρότερα τα χαρακτηριστικά που μπορούν να σχεδιαστούν.
- **DUV** (Deep Ultraviolet, 193 nm): η παλαιότερη τεχνολογία, χρησιμοποιείται ακόμη για τα λιγότερο κρίσιμα στρώματα.
- **EUV** (Extreme Ultraviolet, 13.5 nm): απαραίτητη για τους κόμβους των 5nm και κάτω. Μοναδικός κατασκευαστής στον κόσμο είναι η ολλανδική **ASML** (π.χ. TWINSCAN NXE:3800E).
- **High-NA EUV** (αριθμητικό άνοιγμα 0.55 αντί 0.33): η νεότερη γενιά (TWINSCAN EXE:5000/5200).
  - Κόστος ∼$350–400 εκατ. ανά μηχανή, μέγεθος διώροφου λεωφορείου, μεταφέρεται σε εκατοντάδες κιβώτια.
  - Το 2026 λειτουργούν περίπου 10 τέτοια συστήματα παγκοσμίως (Intel, Samsung, TSMC, imec). Η Intel είναι ο πρώτος πελάτης και τα χρησιμοποιεί για τον κόμβο 14A.

Η ASML σε ένα index fund της Ευρώπης

Vanguard FTSE Europe ETF (VGK): οι 5 μεγαλύτερες θέσεις

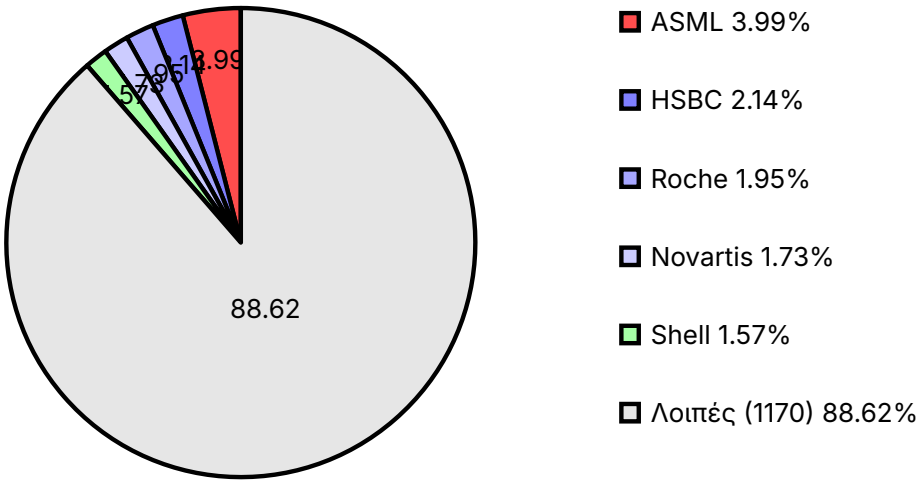

Βάρη στις 9 Οκτ 2026. Πηγή: Pensions & Investments (etf.pionline.com).

- Το VGK ακολουθεί τον δείκτη **FTSE Developed Europe All Cap** (1.175 εταιρείες).
- Η **ASML** είναι η μεγαλύτερη θέση του fund: ∼**4%**, σχεδόν διπλάσια από τη δεύτερη (HSBC).
- Οι 5 μεγαλύτερες θέσεις μαζί: ∼11,4%.
- Μία εταιρεία που φτιάχνει μηχανήματα λιθογραφίας έχει μεγαλύτερο βάρος περισσότερο από κάθε τράπεζα, φαρμακευτική ή πετρελαϊκή της Ευρώπης.

Λιθογραφία: Οι κόμβοι του 2026

- Τα ονόματα των κόμβων (π.χ. «2nm») είναι πλέον εμπορικά και δεν αντιστοιχούν σε κάποια πραγματική διάσταση του transistor.
- Οι πιο προηγμένοι κόμβοι σε μαζική παραγωγή το 2026:
  - **TSMC N2** (2nm): σε παραγωγή από τα τέλη του 2025. Ακολουθεί ο **A16** (1.6nm) το 2026.
  - **Intel 18A**: επεξεργαστές Core Ultra Series 3 (Panther Lake) και Xeon για servers.
  - **Samsung SF2** (2nm).
- Σχεδόν όλα τα AI chips του cloud (NVIDIA, AMD, Google TPU, AWS Trainium) κατασκευάζονται από την TSMC στην Ταϊβάν, κάτι που κάνει την εφοδιαστική αλυσίδα γεωπολιτικά ευαίσθητη.

Μερίδια αγοράς foundries (Q2 2026)

Μερίδιο εσόδων στα 10 μεγαλύτερα foundries (TrendForce, Q2 2026)

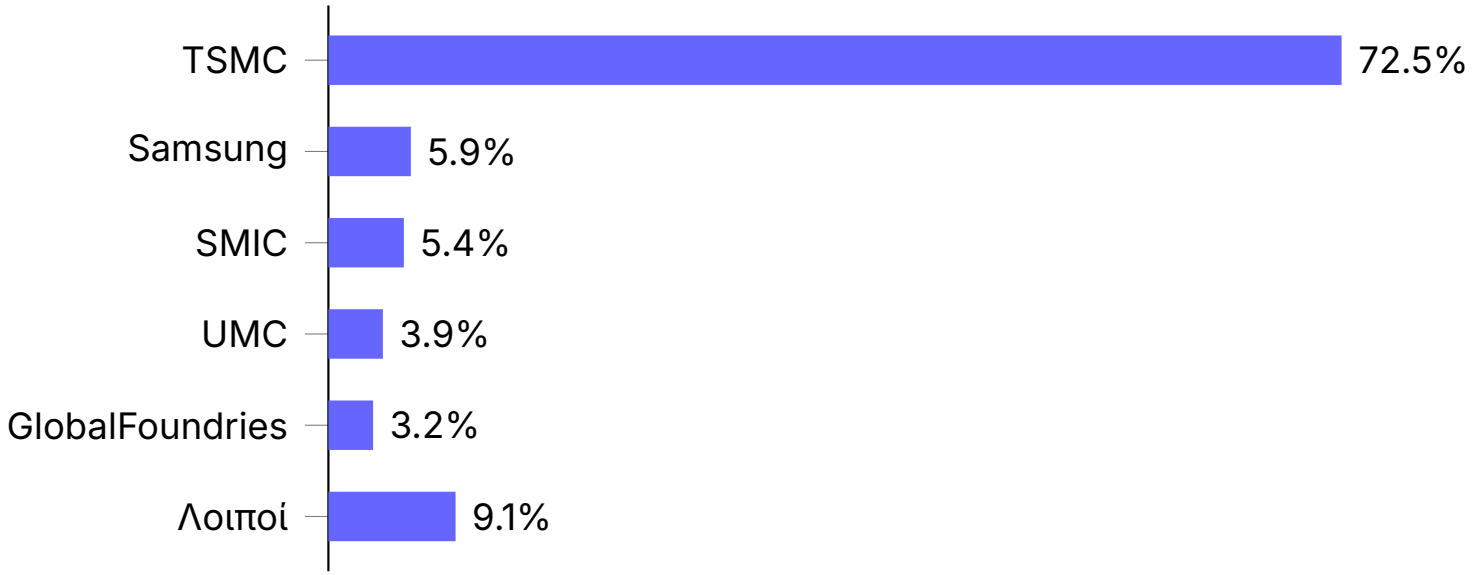

- Συνολικά έσοδα top-10: ∼$53.5 δισ. στο τρίμηνο. Η TSMC μόνη της: ∼$40.2 δισ.
- Η ζήτηση για AI chips διευρύνει το προβάδισμα της TSMC· η κινεζική SMIC πλησιάζει τη Samsung.

Γλωσσάρι: CPU, GPU, TPU, NPU

- **ASIC**: chip φτιαγμένο για μία μόνο δουλειά· πολύ αποδοτικό, αλλά όχι ευέλικτο.
- **SoC**: ένα chip με CPU, GPU, NPU, μνήμη και modem (chips κινητών).
- **Tensor Cores**: μονάδες της GPU που πολλαπλασιάζουν μικρούς πίνακες σε έναν κύκλο.
- **Training / Inference**: εκπαίδευση μοντέλου / χρήση του για απαντήσεις.
- **Latency**: πόσο γρήγορα τελειώνει *μία* εργασία.
- **Throughput**: πόση δουλειά γίνεται συνολικά ανά δευτερόλεπτο.
- **Throughput/Watt**: η ίδια μέτρηση ανά κατανάλωση ενέργειας· κρίσιμη στα data centers (ρεύμα, ψύξη).
- **DDR5**: η RAM της CPU, μεγάλη χωρητικότητα, μέτριο εύρος ζώνης.
- **HBM**: στοίβες DRAM στο ίδιο package με το chip, τεράστιο εύρος ζώνης, ακριβή.
- **Edge**: υπολογισμός στη συσκευή του χρήστη και όχι στο cloud.
- **AI PC**: laptop με ενσωματωμένο NPU.
- **Pod**: σύνολο chips (TPU) που λειτουργούν σαν ένας μεγάλος υπολογιστής.
- **INT8/INT4**: ακέραιοι 8/4 bit· λιγότερο ακριβείς από FP32, αλλά ταχύτεροι και οικονομικότεροι.

SIMT: Single Instruction, Multiple Threads

- **Ιδέα**: σαν έναν δάσκαλο που δίνει *μία* εντολή σε 32 μαθητές, και ο καθένας την εκτελεί στα δικά του νούμερα.
- **Παράδειγμα**: η εντολή είναι «πρόσθεσε». Το νήμα 0 προσθέτει $a_0 + b_0$, το νήμα 1 το $a_1 + b_1$, κ.ο.κ. *Ταυτόχρονα*.
- **Προσοχή**: αν τα νήματα της ίδιας ομάδας χρειάζονται διαφορετικές εντολές (`if/else`), εκτελούνται η μία ομάδα μετά την άλλη και όχι μαζί. Όσο δουλεύει η μία ομάδα, η άλλη περιμένει.

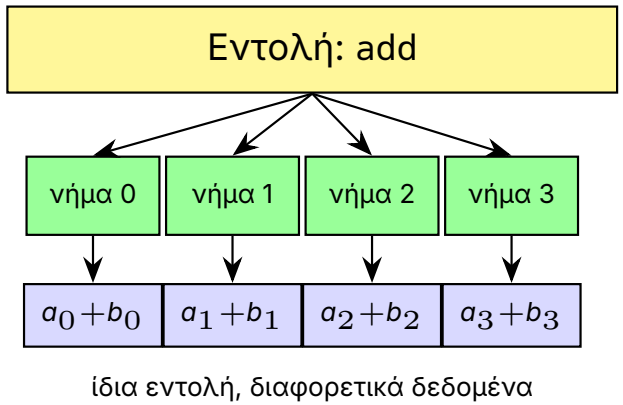

ίδια εντολή, διαφορετικά δεδομένα

GPU: Γιατί όχι μόνο CPU;

- **CPU**: λίγοι (δεκάδες) ισχυροί πυρήνες, μεγάλες caches, σύνθετος έλεγχος. Βελτιστοποιημένη για χαμηλό latency σε σειριακό κώδικα.
- **GPU**: χιλιάδες απλοί πυρήνες που εκτελούν την *ίδια εντολή σε πολλά δεδομένα* (SIMT). Βελτιστοποιημένη για throughput.
- Η εκπαίδευση και το inference των νευρωνικών δικτύων είναι κυρίως πολλαπλασιασμοί πινάκων: ιδανικό παράλληλο φορτίο για GPU.
- Η CPU παραμένει ο «διαχειριστής»: ένας AI server έχει συνήθως 2 CPUs και 4–8 GPUs.

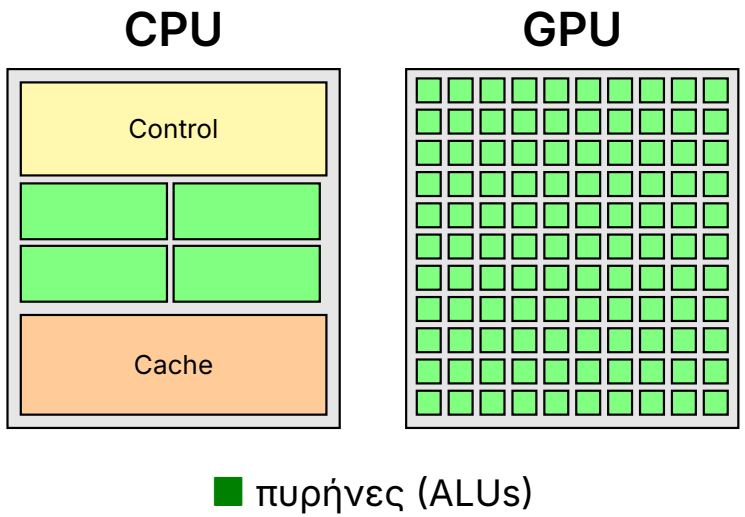

GPU: Βασικά χαρακτηριστικά για AI

- **Tensor Cores**: εξειδικευμένες μονάδες για πολλαπλασιασμό πινάκων, που δίνουν το μεγαλύτερο μέρος της ισχύος στο AI.
- **Ακρίβεια αριθμών**: FP32 $\rightarrow$ FP16/BF16 $\rightarrow$ FP8 $\rightarrow$ FP4. Μικρότερη ακρίβεια σημαίνει περισσότερες πράξεις/sec και λιγότερη μνήμη ανά παράμετρο.
- **Μνήμη HBM** (High Bandwidth Memory): στοίβες DRAM πάνω στο ίδιο package με το chip. Η χωρητικότητα (GB) καθορίζει πόσο μεγάλο μοντέλο χωράει, το εύρος ζώνης (TB/s) πόσο γρήγορα παράγονται tokens.
- **Διασύνδεση**: NVLink (NVIDIA) / Infinity Fabric (AMD) μεταξύ GPUs, πολύ ταχύτερα από PCIe. Κατανάλωση >1 kW ανά GPU. Πλέον μονάδα σχεδίασης είναι ολόκληρο το rack (π.χ. 72 GPUs σε ένα NVLink domain).
- **Λογισμικό**: CUDA (NVIDIA) και ROCm (AMD). Το οικοσύστημα CUDA είναι το μεγαλύτερο ανταγωνιστικό πλεονέκτημα της NVIDIA.

CPU, GPU, TPU, NPU: Συγκριτικά

	CPU	GPU	TPU	NPU
Σχεδίαση	Γενικού σκοπού	Παράλληλος υπολογισμός + Tensor Cores	ASIC για AI (Google)	ASIC για inference μέσα σε SoC
Πυρήνες	Λίγοι, ισχυροί	Χιλιάδες, απλοί	Systolic arrays	Μικρές μονάδες MAC
Στόχος	Χαμηλό latency	Throughput	Throughput ανά Watt	Χαμηλή κατανάλωση
Ευελιξία	Πολύ υψηλή	Υψηλή	Χαμηλή	Πολύ χαμηλή
Μνήμη	DDR5	HBM	HBM	RAM του SoC
Πού	Παντού	Data centers, PC	Google Cloud	Κινητά, laptops
Π.χ.	Xeon, EPYC	H100, MI455X	TPU v7	Apple Neural Engine, Hexagon

Όροι: MAC και Systolic array

- **MAC** (Multiply-Accumulate): η βασική πράξη του AI, $acc \leftarrow acc + a \times b$. Ένας πολλαπλασιασμός πινάκων είναι εκατομμύρια MAC· οι επιταχυντές μετριούνται σε MAC (ή FLOPS) ανά δευτερόλεπτο.
- **Systolic array**: πλέγμα από κελιά MAC. Τα δεδομένα περνούν από κελί σε κελί, σαν το αίμα που αντλεί η καρδιά (απ' όπου το «systolic»).
- Κάθε κελί πολλαπλασιάζει, προσθέτει το μερικό άθροισμα του γείτονα και το προωθεί παρακάτω.
- Ένα δεδομένο διαβάζεται από τη μνήμη *μία φορά* και χρησιμοποιείται σε πολλές πράξεις. Η πρόσβαση στη μνήμη κοστίζει πολύ περισσότερο σε ενέργεια και χρόνο από την πράξη.

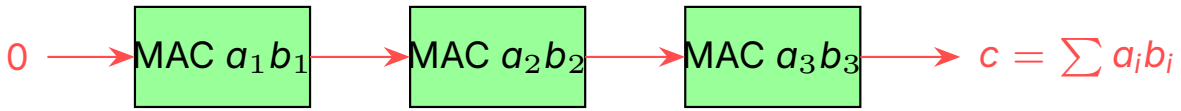

Κάθε κελί προωθεί το μερικό άθροισμα στο επόμενο, χωρίς ενδιάμεση πρόσβαση στη μνήμη.

TPU και NPU: Πώς δουλεύουν

- **TPU**: ASIC της Google (από το 2015). Βασίζεται σε **systolic array**: τα δεδομένα ρέουν από κελί σε κελί και κάθε κελί κάνει πολλαπλασιασμό-πρόσθεση, με ελάχιστες προσβάσεις στη μνήμη.
- Διαθέσιμο μόνο στο Google Cloud, σε pods χιλιάδων chips (Ironwood: έως 9216).
- **NPU**: μικρός επιταχυντής inference μέσα στο SoC (κινητά, «AI PC»). INT8/INT4, λίγα Watt: φωνή, φωτογραφίες, μικρά τοπικά LLMs.
- Cloud: GPU και TPU. Edge: NPU.

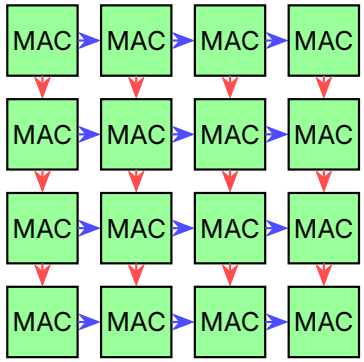

Systolic array 4×4
οριζ.: δεδομένα

κάθ.: αθροίσματα

GPU: State-of-the-art (2026)

Chip	Εταιρεία	Έτος	Μνήμη	Εύρος ζώνης
H100	NVIDIA	2022	80 GB HBM3	3.35 TB/s
B300 (Blackwell U.)	NVIDIA	2025	288 GB HBM3e	8 TB/s
Rubin	NVIDIA	2026	288 GB HBM4	22 TB/s
Instinct MI455X	AMD	2026	432 GB HBM4	$\sim$20–23 TB/s
TPU v7 Ironwood	Google	2025	192 GB HBM3e	7.4 TB/s

- NVIDIA Rubin: 336 δισ. transistors, $\sim$50 PFLOPS σε FP4, κατασκευή TSMC 3nm. Διαθέσιμη στα clouds (AWS, Azure, Google, Oracle, CoreWeave) από το β′ εξάμηνο του 2026.
- AMD MI455X: TSMC 2nm, rack Helios με 72 GPUs, ανταγωνιστής του NVIDIA Vera Rubin NVL72.
- Σε 4 χρόνια (H100 $\rightarrow$ Rubin) η μνήμη ανά GPU $\times$3.6 και το εύρος ζώνης $\times$6.6.

AI accelerators: Η αγορά (2026)

- Η αγορά επιταχυντών για data centers ξεπερνά τα $200 δισ. το 2026, με το inference να αποτελεί όλο και μεγαλύτερο μέρος της.
- **NVIDIA**: ∼75–80% των εσόδων. Πωλεί πλέον ολόκληρα συστήματα (GPUs, CPUs Grace/Vera, NVLink, δικτύωση).
- **AMD**: ∼5–7%, ο σημαντικότερος εναλλακτικός προμηθευτής GPU (συμφωνίες με OpenAI και Meta).
- **Custom chips (ASICs) των hyperscalers**: Google TPU, AWS Trainium, Microsoft Maia, Meta MTIA. Σχεδιάζονται συνήθως με τη βοήθεια της Broadcom ή της Marvell και αναπτύσσονται ταχύτερα από τις GPUs.
- Όλοι τους κατασκευάζονται στην TSMC και χρειάζονται μνήμη HBM από τρεις μόνο προμηθευτές (SK Hynix, Samsung, Micron), που αποτελούν τα σημεία συμφόρησης της εφοδιαστικής αλυσίδας.

GPU wars

		MI300X (Up to)	H100 SXM	AMD Instinct™ Advantage (Up to)
Hardware Specifications	TBP	750W	**700W**	-
	Memory Capacity	192 GB HBM3	80GB HBM3	**2.4x**
	Memory Bandwidth (Peak Theoretical)	5.3 TB/s	3.3TB/s	**1.6x**
HPC Performance (Peak Theoretical)	FP64 Matrix | Vector (TFLOPS)	163.4 | 81.7	66.9 | 33.5	**2.4x | 2.4x**
	FP32 Matrix | Vector (TFLOPS)*	163.4 | 163.4	N/A | 66.9	**N/A | 2.4x**
AI Performance (Peak Theoretical)	TF32 (TFLOPS)	653.7	494.7	**1.3x**
	FP16 (TFLOPS)	1307.4	989.4	**1.3x**
	BFLOAT16 (TFLOPS)	1307.4	989.4	**1.3x**
	FP8 (TFLOPS)	2614.9	1978.9	**1.3x**
	INT8 (TFLOPS)	2614.9	1978.9	**1.3x**

GPU wars 2026: NVIDIA vs AMD

	Σήμερα		Νέα γενιά (2026)	
	NVIDIA B300	**AMD MI355X**	**NVIDIA Rubin**	**AMD MI455X**
Μνήμη	288 GB HBM3e	288 GB HBM3e	288 GB HBM4	432 GB HBM4
Εύρος ζώνης	8 TB/s	8 TB/s	22 TB/s	∼20–23 TB/s
FP4 (dense)	∼14 PFLOPS	∼10 PFLOPS	∼50 PFLOPS	∼40 PFLOPS
Ενοικίαση $/GPU-ώρα	∼5–9	∼3–9	—	—
Rack 72 GPUs	—	—	∼$3,5–8 εκατ.	∼$5–5,5 εκατ.

- Στη σημερινή γενιά τα δύο chips είναι ισοδύναμα σε μνήμη και εύρος ζώνης. Η NVIDIA προηγείται σε FP4 και στο λογισμικό (CUDA), η AMD έχει συχνά χαμηλότερο κόστος ανά token. Στη νέα γενιά η AMD δίνει 50% περισσότερη μνήμη ανά GPU.
- Οι νέες γενιές πωλούνται ως ολόκληρα racks των 72 GPUs, όχι ως μεμονωμένες κάρτες. Το rack της AMD (Helios) εκτιμάται ακριβότερο από το αντίστοιχο της NVIDIA.

Εκτιμήσεις αναλυτών (Futurum, Morgan Stanley), όχι επίσημες τιμές. Ενοικίαση: getdeploying.com (Σεπ 2026), on-demand και spot.

GPU wars: Έσοδα data center της NVIDIA

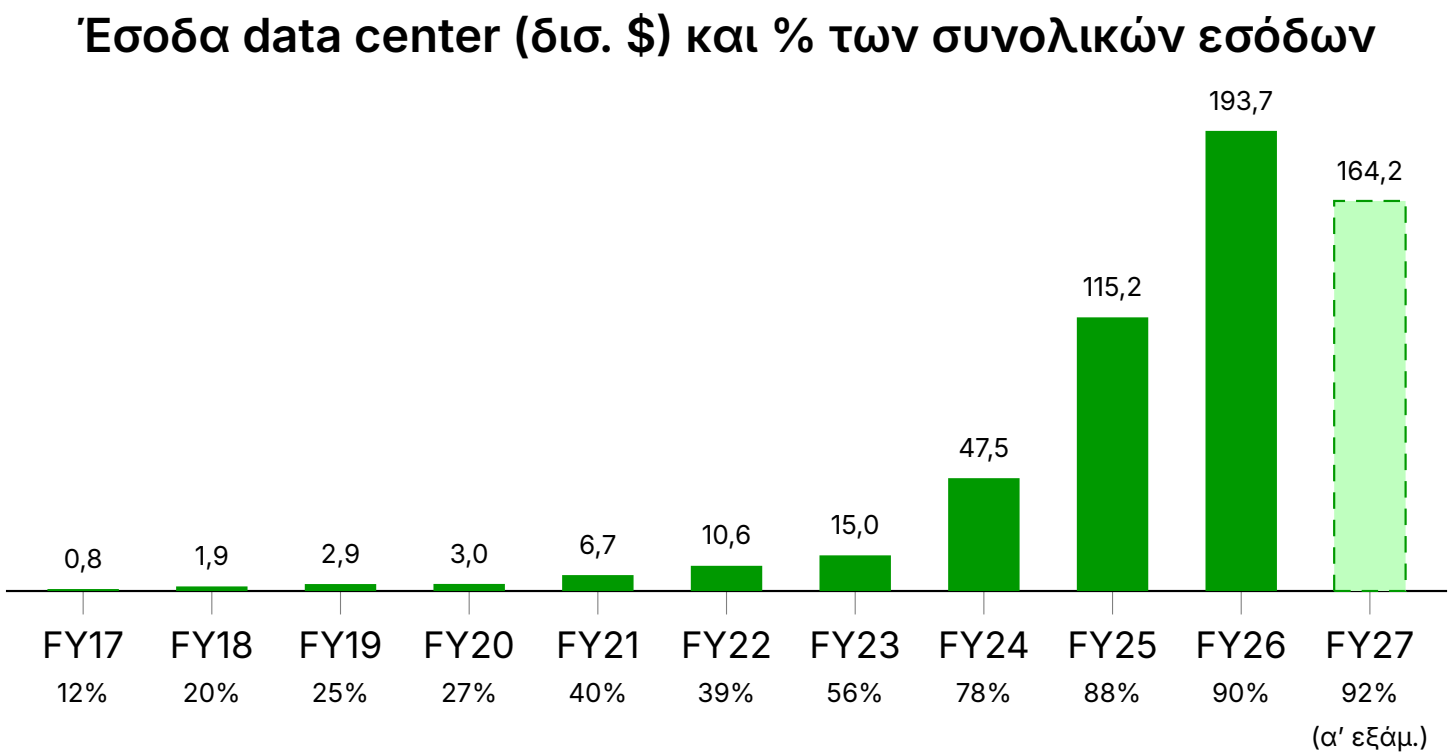

Το οικονομικό έτος της NVIDIA τελειώνει τέλη Ιανουαρίου (FY26 = Φεβ 2025 – Ιαν 2026). Πηγή: NVIDIA.

- Από $0,8 δισ. (FY17) σε $193,7 δισ. (FY26): το data center είναι πλέον πάνω από το 90% της NVIDIA.
- Q2 FY27 (Ιούλ 2026): $89 δισ. μόνο σε ένα τρίμηνο, +117% σε ετήσια βάση.

GPU wars: Η μετοχή της NVIDIA

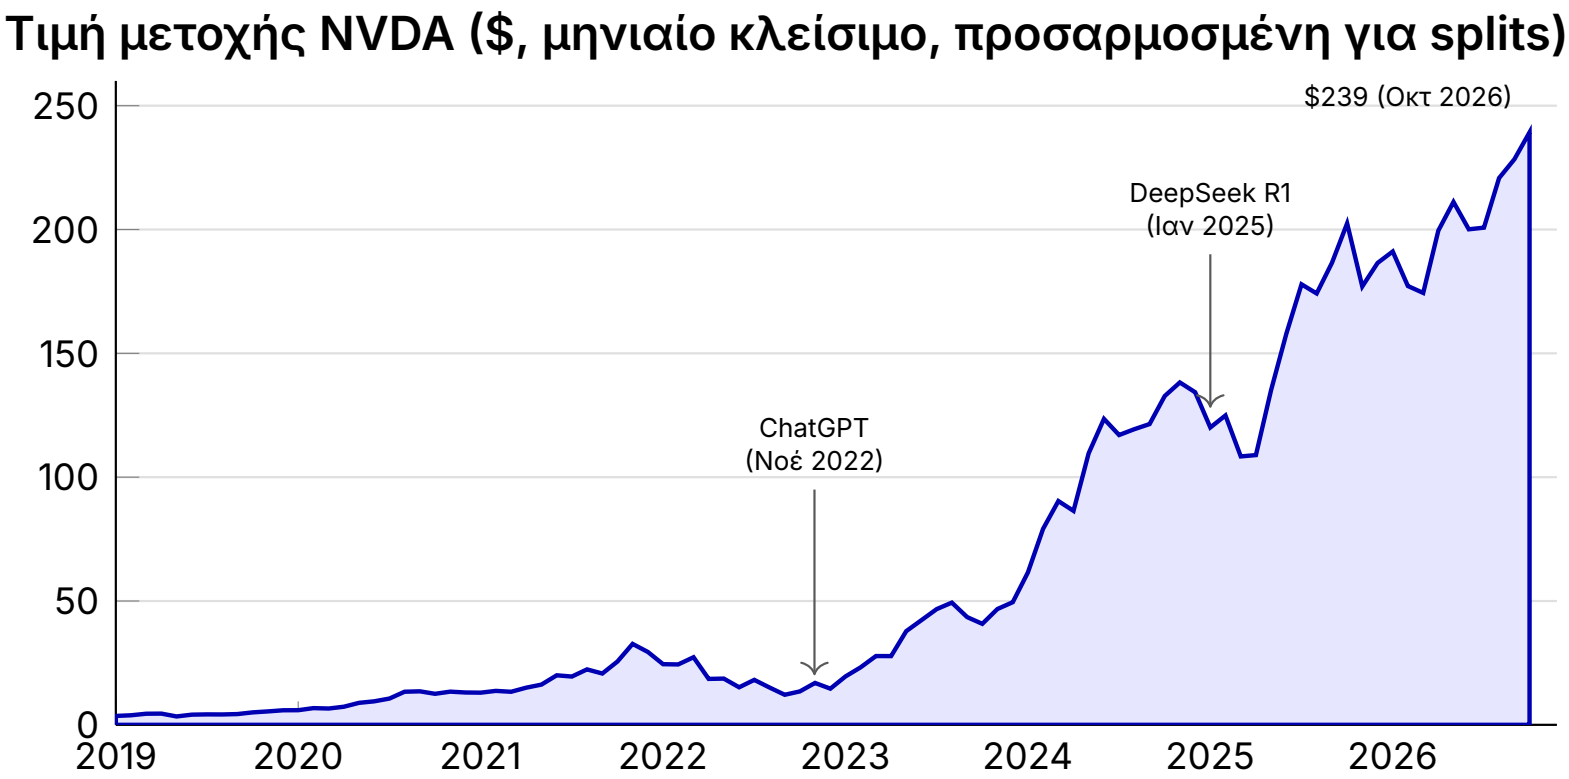

Πηγή: Yahoo Finance. Splits: 4:1 (2021), 10:1 (2024).

- Από $3,6 (Ιαν 2019) σε $239 (Οκτ 2026): περίπου 65 φορές πάνω.
- Η εκτίναξη ξεκινά με την έλευση του ChatGPT και τη ζήτηση για GPUs στα data centers.

GPU wars



“Let’s wait 10 years and see where it actually goes before we make all these crazy announcements.” - Linus Torvalds

GPU wars

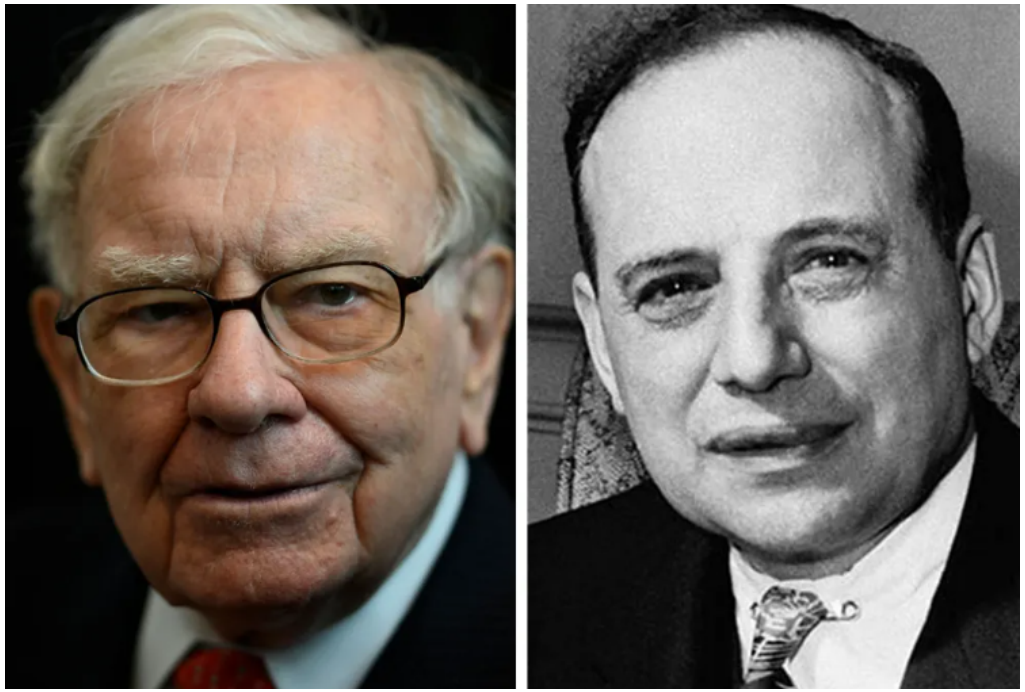

“Those who do not remember the past are condemned to repeat it.”
“Stocks become more risky, not less, as their prices rise”
(Benjamin Graham)

Τι περιέχει ο δείκτης S&P 500;

Οι 20 μεγαλύτερες εταιρείες (% του δείκτη)

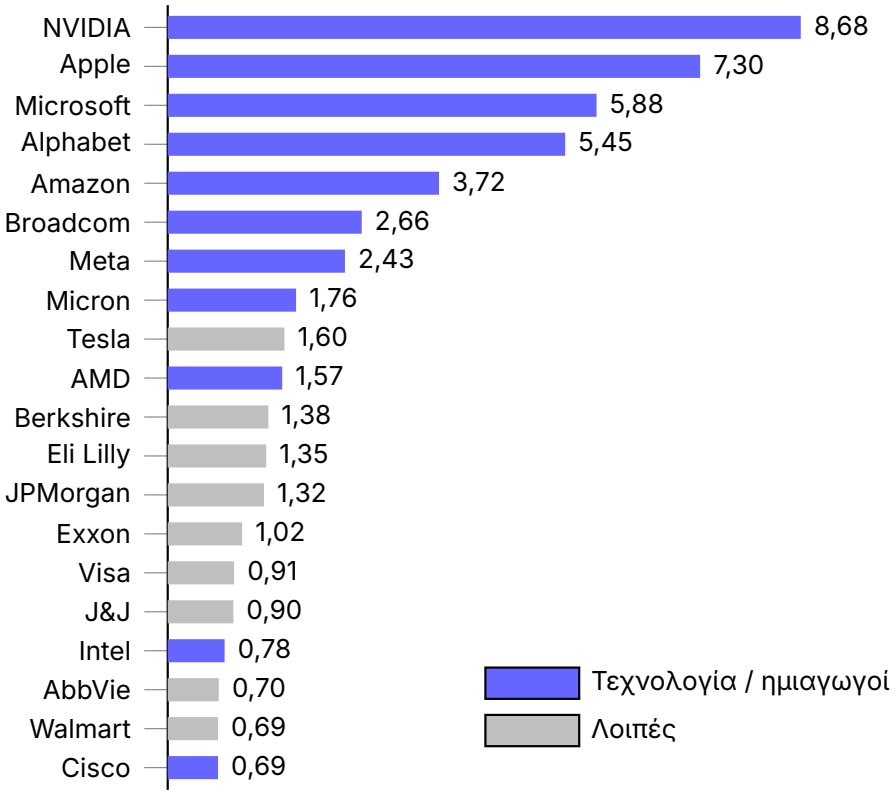

Συγκέντρωση του δείκτη

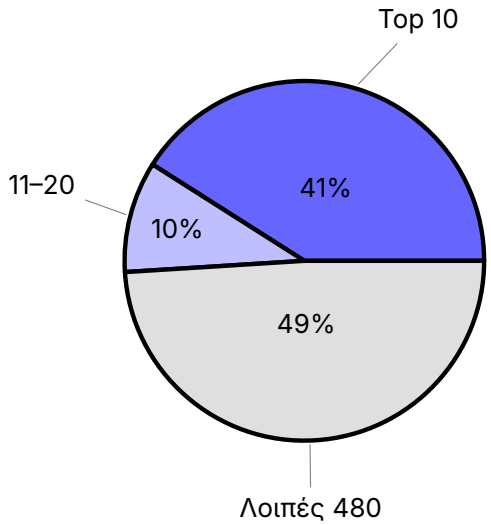

- 20 από τις 500 εταιρείες = **51%** του δείκτη.
- Οι 11 εταιρείες τεχνολογίας του top 20 μόνες τους = **41%**.
- Ένα «διασπαρμένο» index fund είναι στην πράξη ένα μεγάλο στοίχημα στην AI.

Βάρη στις 6 Οκτ 2026 (εκτίμηση βάσει των holdings του SPY). Πηγή: chartrow.com.

Index funds τεχνολογίας: Το VGT

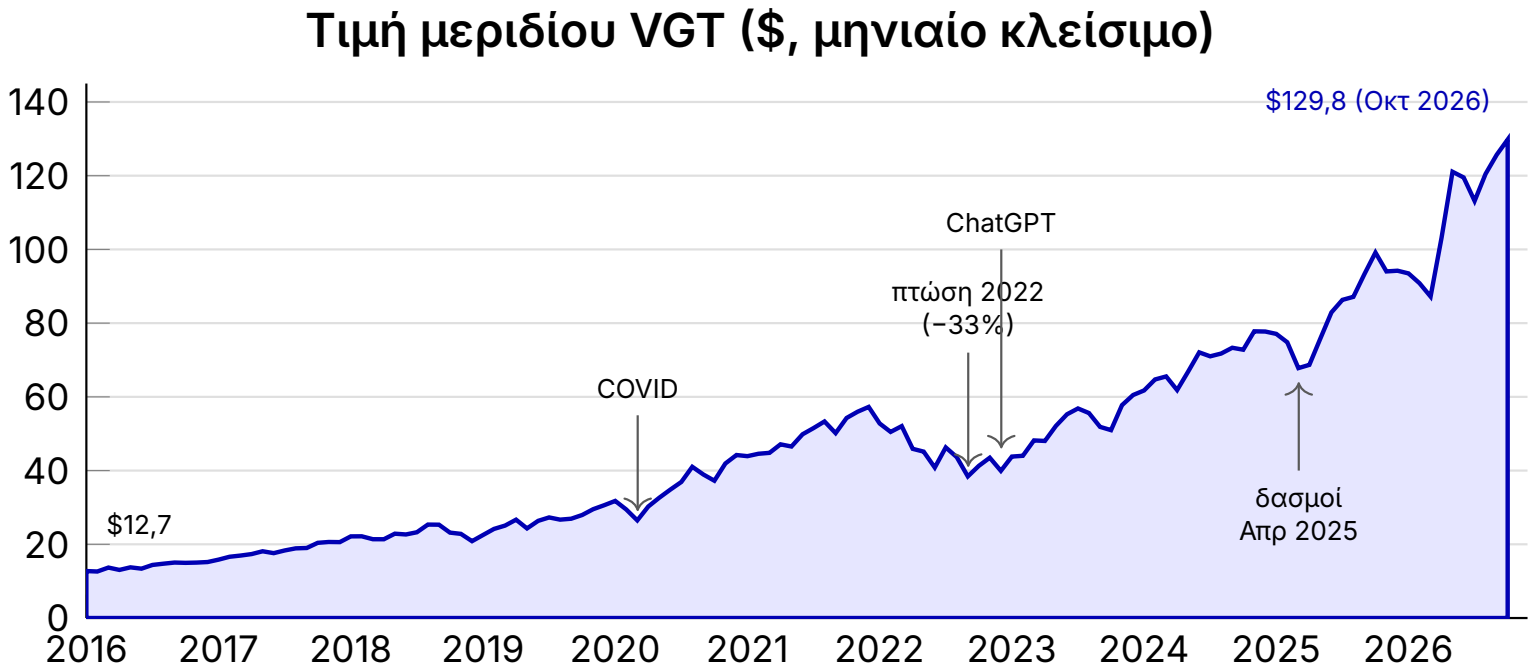

Τιμές προσαρμοσμένες για το split 8:1 (Απρ 2026). Πηγή: Yahoo Finance.

- Το VGT (Vanguard Information Technology ETF) παρακολουθεί περίπου 300 εταιρείες τεχνολογίας, αλλά τα κεφάλαιά του είναι συγκεντρωμένα σε λίγες (NVIDIA, Apple, Microsoft, Broadcom).
- Από το 2016 η τιμή δεκαπλασιάστηκε ($12,7 → $129,8), με απότομες πτώσεις στη διαδρομή (2020, 2022, 2025).

Οι τιμές των GPUs στον χρόνο

Home: RTX 5090, χαμηλότερη τιμή ($)

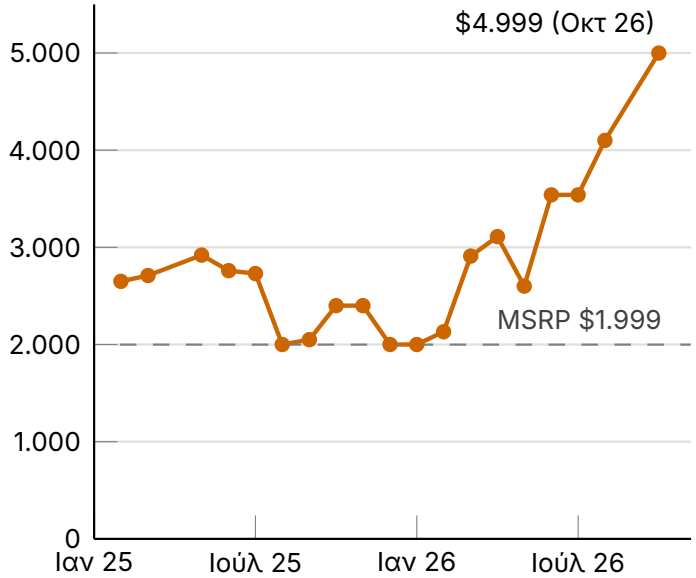

Enterprise: H100, ενοικίαση ($/GPU-ώρα)

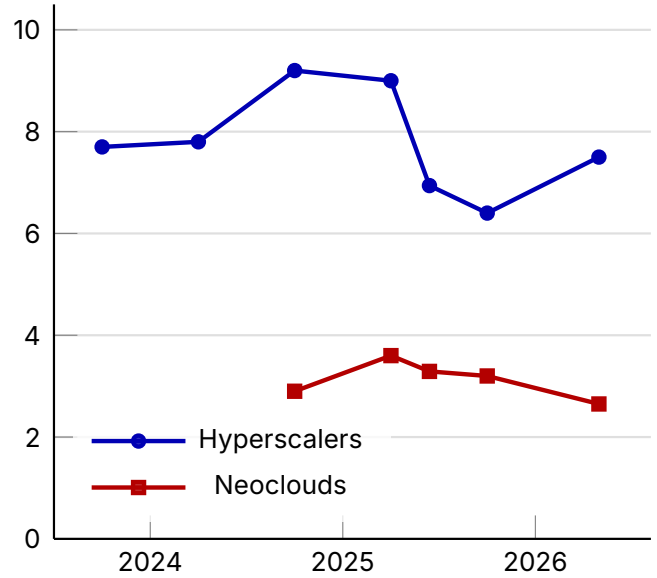

Πηγές: TrackaLacker, BestValueGPU (RTX 5090)· Silicon Data H100 Rental Index (H100). Ενδεικτικές τιμές.

- RTX 5090: κυκλοφόρησε στα $1.999 (Ιαν 2025)· το 2026 πουλιέται πάνω από 2,5× το **MSRP** (Manufacturer's Suggested Retail Price, η προτεινόμενη τιμή λιανικής του κατασκευαστή), γιατί αγοράζεται και για AI.
- H100: τιμή αγοράς ~$25–40 χιλ. ανά GPU. Η ενοικίαση στους neoclouds κοστίζει περίπου το 1/3 των hyperscalers.

PCIe: PCI Express

- Ο δίαυλος που συνδέει τη CPU με τις περιφερειακές κάρτες: GPUs, NVMe SSDs, κάρτες δικτύου (NICs).
- Σειριακή σύνδεση σημείο-προς-σημείο σε **lanes**: x1, x4 (NVMe SSD), x8, x16 (GPU). Περισσότερα lanes = μεγαλύτερο εύρος ζώνης.
- Κάθε νέα γενιά **διπλασιάζει** την ταχύτητα ανά lane.

Γενιά	Έτος	GT/s ανά lane	GB/s ανά lane	GB/s σε x16
PCIe 3.0	2010	8	∼1	∼16
PCIe 4.0	2017	16	∼2	∼32
PCIe 5.0	2019	32	∼4	∼64
PCIe 6.0	2022	64	∼8	∼128
PCIe 7.0	2025	128	∼16	∼256

Έτος = δημοσίευση της προδιαγραφής· τα προϊόντα ακολουθούν 2–3 χρόνια αργότερα. Ταχύτητες ανά κατεύθυνση.

- 2026: το PCIe 5.0 είναι το standard (π.χ. RTX 5090: PCIe 5.0 x16). Το PCIe 6.0 μπαίνει στους AI servers: μια κάρτα δικτύου 800 Gb/s (≈100 GB/s) δεν χωράει σε PCIe 5.0 x16.
- Μεταξύ GPUs το PCIe δεν αρκεί: το NVLink 5 δίνει 1.8 TB/s ανά GPU, ∼14× το PCIe 5.0 x16.
- Στη virtualization μια κάρτα PCIe δίνεται απευθείας σε ένα VM (PCI passthrough).

NVLink: Διασύνδεση GPU-με-GPU

- Η εκπαίδευση και το inference μεγάλων μοντέλων μοιράζονται σε πολλές GPUs, που ανταλλάσσουν συνεχώς δεδομένα (βάρη, gradients, KV cache).
- Μέσω PCIe η κίνηση περνά από switch ή CPU και περιορίζεται στα ∼64 GB/s. Το **NVLink** της NVIDIA συνδέει τις GPUs απευθείας, με εύρος ζώνης TB/s.
- Το **NVSwitch** είναι chip-μεταγωγέας: κάθε GPU μιλά με κάθε άλλη στην πλήρη ταχύτητα, σαν να ήταν μία μεγάλη GPU.

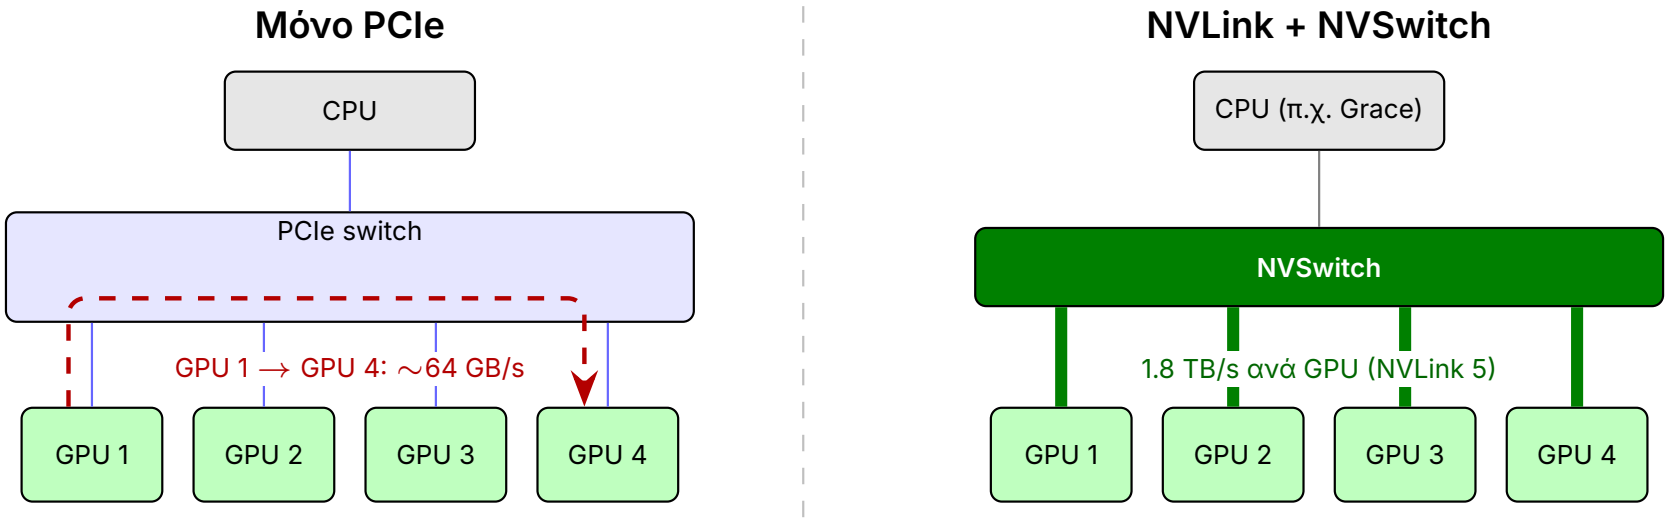

Απλοποιημένο σχήμα: σε ένα HGX server συνδέονται 8 GPUs, σε ένα rack NVL72 72 GPUs.

NVLink: Γενιές και κλίμακα

Γενιά	GPU	Έτος	Εύρος ζώνης ανά GPU
NVLink 1	P100	2016	160 GB/s
NVLink 2	V100	2017	300 GB/s
NVLink 3	A100	2020	600 GB/s
NVLink 4	H100	2022	900 GB/s
NVLink 5	Blackwell (B200/B300)	2024	1.8 TB/s
NVLink 6	**Rubin**	**2026**	**3.6 TB/s**

Συνολικό εύρος ζώνης (και στις δύο κατευθύνσεις). Για σύγκριση: PCIe 5.0 x16 $\approx$ 128 GB/s.

- **NVL72**: με NVSwitch σε όλο το rack, 72 GPUs (π.χ. GB300 NVL72) σχηματίζουν ένα NVLink domain: λειτουργούν σαν ένας υπολογιστής με $\sim$20 TB μνήμη HBM.
- Πέρα από το rack, τα racks συνδέονται με InfiniBand ή Ethernet (800G), που είναι πολύ πιο αργά από το NVLink.
- Το NVLink είναι κλειστό πρότυπο της NVIDIA (με το **NVLink Fusion** ανοίγει σε CPUs/chips τρίτων). Οι ανταγωνιστές (AMD, Google, AWS, Meta κ.ά.) προωθούν το ανοιχτό **UALink**. Η AMD χρησιμοποιεί και το δικό της Infinity Fabric.

Σκληροί δίσκοι

Τύπος Δίσκου:

- HDD (Hard Disk Drive): Χρησιμοποιεί μαγνητικούς δίσκους για αποθήκευση δεδομένων. Έχει μεγαλύτερη χωρητικότητα σε χαμηλότερη τιμή, αλλά χαμηλότερη ταχύτητα σε σχέση με τα SSD.
- SSD (Solid State Drive): Χρησιμοποιεί μνήμη flash χωρίς κινούμενα μέρη, προσφέροντας πολύ γρηγορότερη απόδοση (ταχύτητα ανάγνωσης/εγγραφής) και καλύτερη ανθεκτικότητα.

Χωρητικότητα



Χωρητικότητα

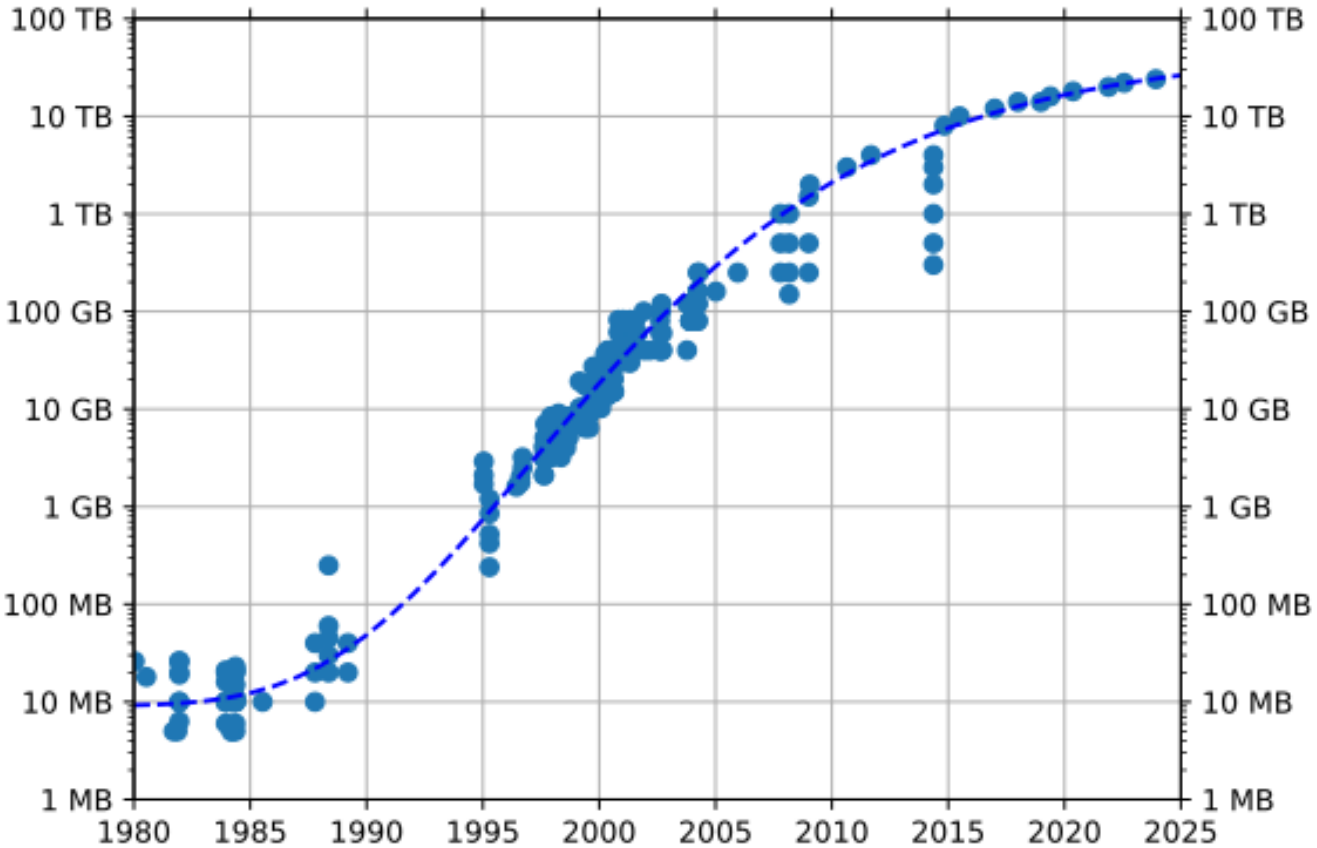

Ταχύτητα περιστροφής (για HDD)

Τύπος Δίσκου:

- Η ταχύτητα περιστροφής ενός σκληρού δίσκου HDD (Hard Disk Drive) αναφέρεται στην ταχύτητα με την οποία περιστρέφονται οι μαγνητικοί δίσκοι (πλατό) στο εσωτερικό του.
- Μετριέται σε RPM (Revolutions Per Minute), δηλαδή σε περιστροφές ανά λεπτό, και επηρεάζει άμεσα την ταχύτητα με την οποία ο δίσκος μπορεί να διαβάσει και να γράψει δεδομένα.
- 7200 RPM: Προτιμάται για καλύτερη απόδοση σε εφαρμογές όπως παιχνίδια, επεξεργασία βίντεο και καθημερινή χρήση όπου απαιτείται γρηγορότερη πρόσβαση σε δεδομένα.
- 10,000-15,000 RPM: Χρησιμοποιούνται σε περιβάλλοντα όπου η ταχύτητα είναι κρίσιμη, όπως βάσεις δεδομένων και συστήματα υψηλής απόδοσης.

Διεπαφή SATA

- Η SATA (Serial ATA - Serial Advanced Technology Attachment) είναι μια διεπαφή που χρησιμοποιείται για τη σύνδεση σκληρών δίσκων (HDD), SSD και οπτικών συσκευών με τη motherboard.
- Αποτελεί το πιο ευρέως διαδεδομένο πρότυπο σύνδεσης για αποθηκευτικές μονάδες στους περισσότερους υπολογιστές και laptops.
- SATA I: Υποστηρίζει μέγιστη ταχύτητα μεταφοράς δεδομένων έως 1.5 Gbps.
- SATA II: Υποστηρίζει ταχύτητα έως 3 Gbps.
- SATA III: Η πιο κοινή έκδοση σήμερα, υποστηρίζει ταχύτητα έως 6 Gbps.
- Hot Swap (dont try this at home!)

NVMe: Non-Volatile Memory Express

- Είναι ένα πρωτόκολλο επικοινωνίας που έχει σχεδιαστεί ειδικά για συσκευές αποθήκευσης SSD που χρησιμοποιούν την τεχνολογία PCIe.
- Επιτρέπει στα SSDs να αξιοποιούν την υψηλή ταχύτητα του διαύλου PCIe και να επικοινωνούν πιο αποδοτικά με τη CPU και τη μνήμη του συστήματος.
- Οι NVMe SSDs μπορούν να επιτύχουν ταχύτητες ανάγνωσης και εγγραφής έως και $\sim$7 GB/s σε PCIe 4.0 και $\sim$14 GB/s σε PCIe 5.0 (ανάλογα με το PCIe slot).
- Μικρότερη καθυστέρηση (latency) σε σχέση με το SATA.
- Πολλαπλοί δίαυλοι (parallel command queues).

SAS: Serial Attached SCSI

- Διεπαφή αποθήκευσης που χρησιμοποιείται κυρίως σε επαγγελματικά συστήματα, όπως servers και data centers.
- βασίζεται στο πρωτόκολλο SCSI (Small Computer System Interface).
- Οι δίσκοι με SAS μπορούν να επιτύχουν ταχύτητες μεταφοράς δεδομένων από 3 Gbps έως 24 Gbps.
- Οι δίσκοι SAS είναι πιο αξιόπιστοι και συχνά έχουν μεγαλύτερη διάρκεια ζωής, με καλύτερους μηχανισμούς διόρθωσης σφαλμάτων.
- full-duplex λειτουργία, που σημαίνει ότι μπορεί να στέλνει και να λαμβάνει δεδομένα ταυτόχρονα

Form Factor(μέγεθος)

- 2.5 ίντσες: Τυπικό μέγεθος για φορητούς δίσκους HDD και SSD.
- 3.5 ίντσες: Χρησιμοποιείται κυρίως σε επιτραπέζιους υπολογιστές για HDDs.
- M.2: Πολύ μικρός SSD για φορητούς υπολογιστές και σύγχρονα desktops, συχνά χρησιμοποιείται με PCIe/NVMe.
- U.2: Χρησιμοποιείται σε servers και workstations για SSD υψηλής ταχύτητας.

Switches (μεταγωγείς)

- Ο βασικός ρόλος του είναι να δρομολογεί την κυκλοφορία των δεδομένων μεταξύ των συσκευών αυτών, χρησιμοποιώντας τη διεύθυνση MAC (Media Access Control) κάθε συσκευής, ώστε να προωθεί τα δεδομένα μόνο στην προορισμένη συσκευή.

- Top-of-Rack (ToR): Τοποθετούνται στην κορυφή κάθε rack σε ένα data center και συνδέουν όλους τους servers του συγκεκριμένου rack μεταξύ τους, καθώς και με το υπόλοιπο δίκτυο του data center.
- End-of-Row (EoR): Τοποθετούνται στο τέλος κάθε σειράς (row) από racks και συνδέουν όλους τους servers που βρίσκονται στα racks της σειράς αυτής.
- Core: αποτελούν την κεντρική ραχοκοκαλιά του δικτύου ενός data center. Συνδέουν τα ToR ή EoR switches μεταξύ τους, επιτρέποντας την επικοινωνία μεταξύ διαφορετικών racks ή σειρών racks.

Αρχιτεκτονική

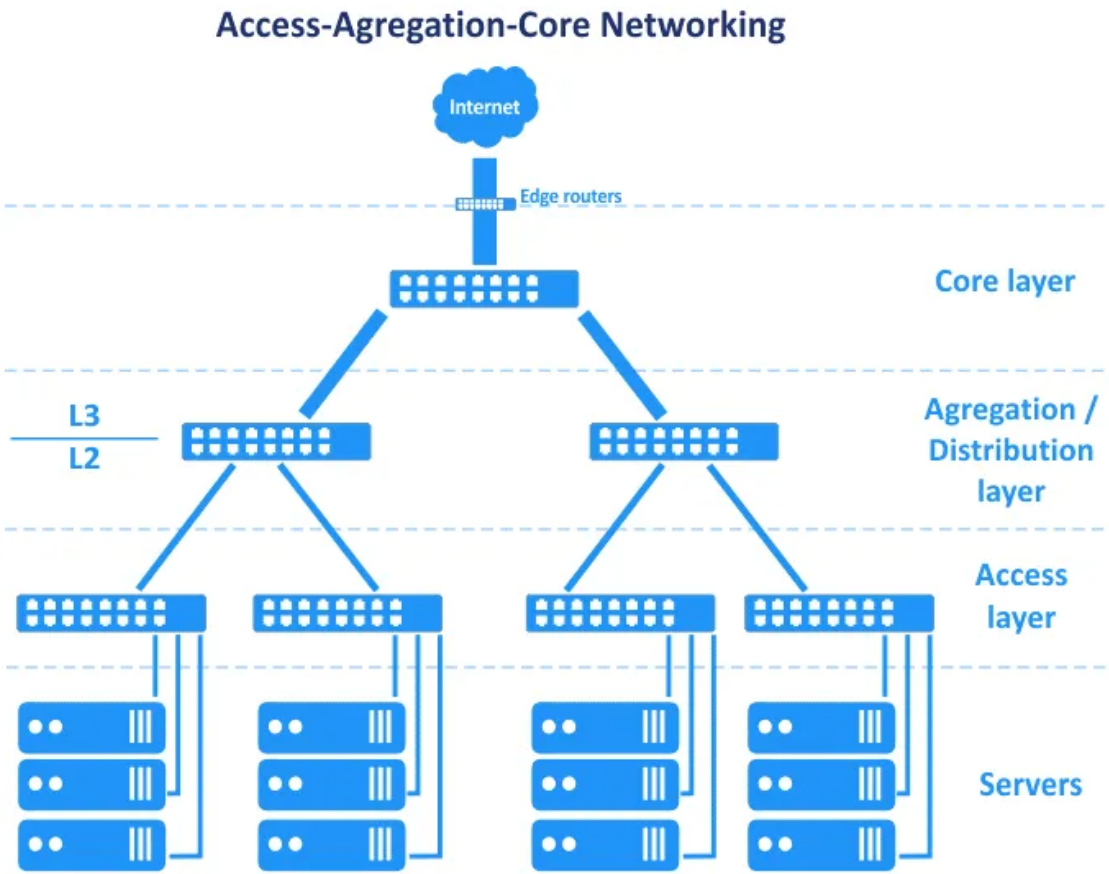

L2/L3 Switch

- Λειτουργεί στα επίπεδα 2 (MAC) και 3 (Network)
- Προωθεί πακέτα μέσω διευθύνσεων MAC και IP
- Δρομολογεί κίνηση μεταξύ VLAN
- Υποστηρίζει διάφορα πρωτόκολλα δρομολόγησης όπως BGP.
- Το BGP είναι ένα από τα πιο σημαντικά πρωτόκολλα δρομολόγησης που χρησιμοποιούνται σήμερα, καθώς επιτρέπει τη διασύνδεση και τη δρομολόγηση μεταξύ διαφορετικών δικτύων σε παγκόσμια κλίμακα. Είναι απαραίτητο για τη λειτουργία του Διαδικτύου και παρέχει σταθερότητα, ασφάλεια και δυνατότητες διαμόρφωσης πολιτικών δρομολόγησης μεταξύ αυτόνομων συστημάτων.

Routers (δρομολογητές)

- μια συσκευή δικτύου που συνδέει πολλαπλά δίκτυα και δρομολογεί την κίνηση δεδομένων μεταξύ αυτών των δικτύων. Ο κύριος ρόλος του είναι να δρομολογεί τα πακέτα δεδομένων από τη μία συσκευή στην άλλη, συνήθως μεταξύ ενός τοπικού δικτύου (LAN) και ενός ευρύτερου δικτύου (όπως το διαδίκτυο).

Switches vs Routers

- Ένα switch L2/L3 είναι και δρομολογητής. Υποστηρίζει και πρωτόκολλα δρομολόγησης όπως το BGP.
- Το hardware ενός L2/L3 switch χρησιμοποιεί ASIC για καλύτερη απόδοση σε τοπικά δίκτυα (LAN).
- Το L2/L3 δεν έχει θύρες WAN και τα χαρακτηριστικά που συνήθως διαθέτει ένας παραδοσιακός δρομολογητής.
- Το L2/L3 χρησιμοποιείται κυρίως για την υποστήριξη της δρομολόγησης μεταξύ VLANs.

Καλώδια χαλκού

UTP Categories - Copper Cable				
UTP Category	**Data Rate**	**Max. Length**	**Cable Type**	**Application**
CAT1	Up to 1Mbps	-	Twisted Pair	Old Telephone Cable
CAT2	Up to 4Mbps	-	Twisted Pair	Token Ring Networks
CAT3	Up to 10Mbps	100m	Twisted Pair	Token Rink & 10BASE-T Ethernet
CAT4	Up to 16Mbps	100m	Twisted Pair	Token Ring Networks
CAT5	Up to 100Mbps	100m	Twisted Pair	Ethernet, FastEthernet, Token Ring
CAT5e	Up to 1 Gbps	100m	Twisted Pair	Ethernet, FastEthernet, Gigabit Ethernet
CAT6	Up to 10Gbps	100m	Twisted Pair	GigabitEthernet, 10G Ethernet (55 meters)
CAT6a	Up to 10Gbps	100m	Twisted Pair	GigabitEthernet, 10G Ethernet (55 meters)
CAT7	Up to 10Gbps	100m	Twisted Pair	GigabitEthernet, 10G Ethernet (100 meters)

Οπτικές Ίνες

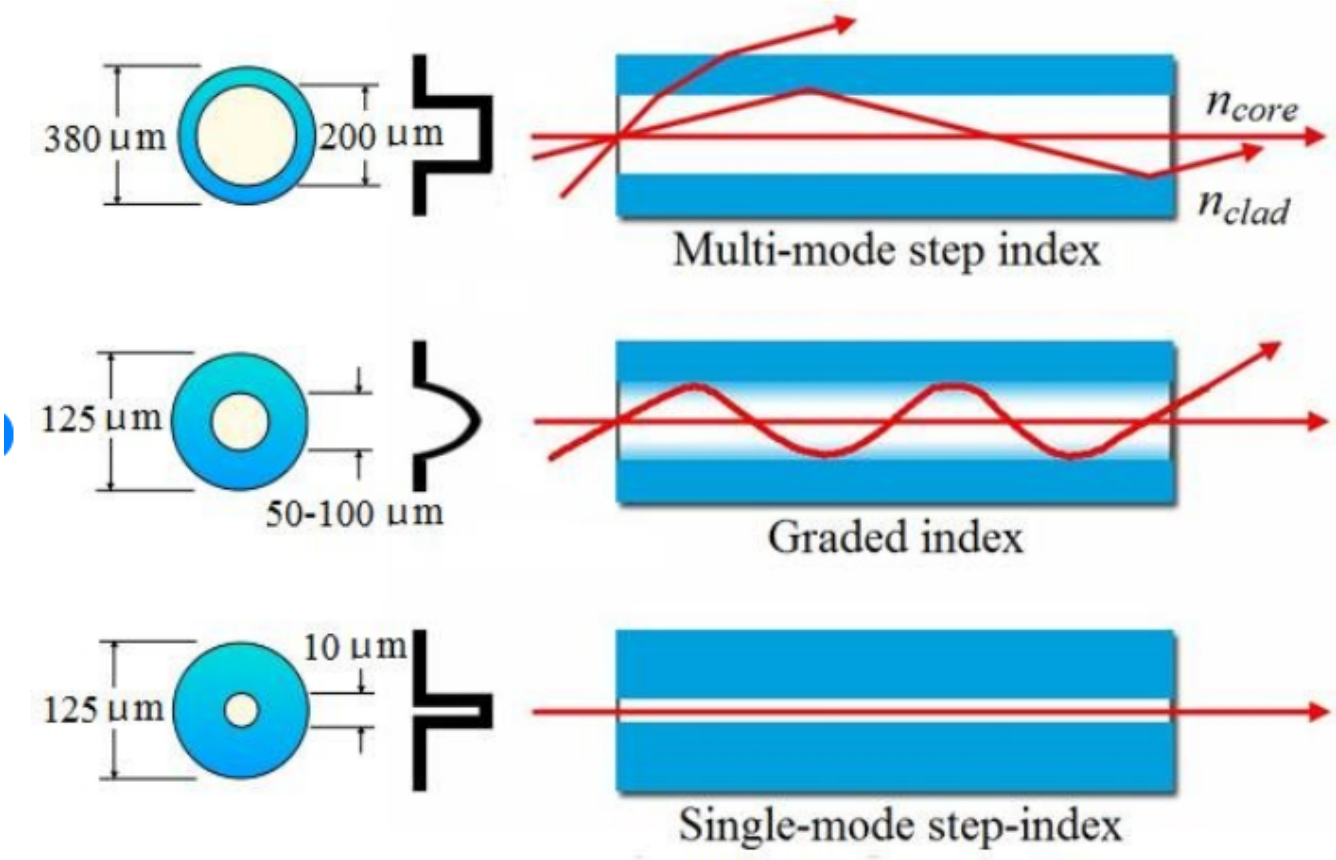

Ταχύτητες

The Evolution of Ethernet Standards to Meet Higher Speeds				
Date	IEEE Std.	Name	Data Rate	Type of Cabling
1990	802.3i	10BASE-T	10 Mb/s	Category 3 cabling
1995	802.3u	100BASE-TX	100 Mb/s*	Category 5 cabling
1998	802.3z	1000BASE-SX	1 Gb/s	Multimode fiber
	802.3z	1000BASE-LX/EX		Single mode fiber
1999	802.3ab	1000BASE-T	1 Gb/s*	Category 5e or higher Category
2003	802.3ae	10GBASE-SR	10 Gb/s	Laser-Optimized MMF
	802.3ae	10GBASE-LR/ER		Single mode fiber
2006	802.3an	10GBASE-T	10 Gb/s*	Category 6A cabling
2015	802.3bq	40GBASE-T	40 Gb/s*	Category 8 (Class I & II) Cabling
2010	802.3ba	40GBASE-SR4/LR4	40 Gb/s	Laser-Optimized MMF or SMF
	802.3ba	100GBASE-SR10/LR4/ER4	100 Gb/s	Laser-Optimized MMF or SMF
2015	802.3bm	100GBASE-SR4	100 Gb/s	Laser-Optimized MMF
2016	SG	Under development	400 Gb/s	Laser-Optimized MMF or SMF
Note: *with auto negotiation				

Μέγιστες Αποστάσεις

Ethernet Type	Bandwidth	Cable Type	Maximum Distance
10Base-T	10Mbps	Cat 3/Cat 5 UTP	100m
100Base-TX	100Mbps	Cat 5 UTP	100m
100Base-TX	200Mbps	Cat 5 UTP	100m
100Base-FX	100Mbps	Multi-mode fiber	400m
100Base-FX	200Mbps	Multi-mode fiber	2Km
1000Base-T	1Gbps	Cat 5e UTP	100m
1000Base-TX	1Gbps	Cat 6 UTP	100m
1000Base-SX	1Gbps	Multi-mode fiber	550m
1000Base-LX	1Gbps	Single-mode fiber	2Km
10GBase-T	10Gbps	Cat 6a/Cat 7 UTP	100m
10GBase-LX	10Gbps	Multi-mode fiber	100m
10GBase-LX	10Gbp	Single-mode fiber	10Km