MEDLAB
MEDICAL TECHNOLOGY & INTELLIGENT INFORMATION SYSTEMS

Τεχνητή Νοημοσύνη και Επιστήμη των Υλικών



- Διδάσκων: Δημήτριος Ι. Φωτιάδης
- Τμήμα Μηχανικών Επιστήμης Υλικών
- Website: https://medlab.cc.uoi.gr/

- Ιωάννινα 2026 - 2027

Περιεχόμενα



1. Εισαγωγή στην Τεχνητή Νοημοσύνη και τη Σύγχρονη Μηχανική
2. Θεμελιώδεις Έννοιες της Τεχνητής Νοημοσύνης
3. Ιστορική Εξέλιξη και Σύγχρονη Ανάπτυξη της Τεχνητής Νοημοσύνης
4. Βασικές Κατηγορίες και Εργασίες Μηχανικής Μάθησης
5. Δεδομένα, Αναπαράσταση και Μοντέλα Μηχανικής Μάθησης
6. Εκπαίδευση, Αξιολόγηση και Ικανότητα Γενίκευσης
7. Αλγόριθμοι, Ροή Εργασίας και Περιορισμοί της Μηχανικής Μάθησης
8. Εφαρμογές στην Επιστήμη και Μηχανική Υλικών

Βασική Πηγή: Liu, Z. (2025). *Artificial Intelligence for Engineers*.



Ενότητα 1

Εισαγωγή στην Τεχνητή Νοημοσύνη και τη Σύγχρονη Μηχανική

Αντικείμενο και μαθησιακοί στόχοι

Αντικείμενο του Μαθήματος

Οι βασικές έννοιες της Τεχνητής Νοημοσύνης **(ΤΝ)** και της **Μηχανικής Μάθησης (ΜΜ)** και ο τρόπος με τον οποίο εφαρμόζονται σε προβλήματα Μηχανικής και Επιστήμης Υλικών.

AI for Eng.

Βασικό βοήθημα

Z. Liu, Artificial Intelligence for Engineers: Basics and Implementations

Springer, 2025

Στο τέλος της διάλεξης θα μπορείτε να:

1. Εξηγείτε τι είναι η ΤΝ και η Μηχανική Μάθηση
2. Χρησιμοποιείτε σωστά το βασικό λεξιλόγιο: δεδομένα, μοντέλο, εκπαίδευση, αξιολόγηση
3. Αναγνωρίζετε σε ποια κατηγορία μάθησης ανήκει ένα πρόβλημα
4. Περιγράφετε την ροή εργασίας ενός έργου Μηχανικής Μάθησης
5. Εξηγείτε train/test, γενίκευση, υπο- και υπερ-προσαρμογή

Βασική Πηγή: Liu, Z. (2025). *Artificial Intelligence for Engineers*.

Τεχνητή Νοημοσύνη και Επιστήμη των Υλικών

Γιατί η ΤΝ αφορά τον μηχανικό υλικών;

- Η ΤΝ θεωρείται ο **πυρήνας της 4ης βιομηχανικής επανάστασης** (Industry 4.0)
- Η μηχανική επηρεάζεται και «συγχωνεύεται» ολοένα περισσότερο με την ΤΝ
- Η Επιστήμη Υλικών παράγει μεγάλο όγκο δεδομένων: πειράματα, μικροσκοπία, προσομοιώσεις
- Ο μηχανικός χρειάζεται ένα φάσμα γνώσεων: από τη **χρήση** έτοιμων εργαλείων μέχρι την **αξιολόγηση, τροποποίηση** και **ανάπτυξη** αλγορίθμων

Ανάπτυξη
Νέοι, πιο σύνθετοι αλγόριθμοι

Τροποποίηση
Προσαρμογή μεθόδων στο πρόβλημα υλικών

Αξιολόγηση
Κρίση για το αν ένα μοντέλο είναι αξιόπιστο

Χρήση
Κοινές τεχνικές ΤΝ ως «εργαλειοθήκη»

↑ *Επίπεδα εξοικείωσης με την ΤΝ*

Βασική Πηγή: Liu, Z. (2025). *Artificial Intelligence for Engineers*.

Η ΤΝ γύρω μας

Η Μηχανική Μάθηση χρησιμοποιείται σήμερα σχεδόν **σε κάθε τομέα**: πληροφορική, υγεία, χρηματοοικονομικά, υλικά, επικοινωνίες. Μερικά παραδείγματα από την καθημερινότητα:

Αυτόνομα οχήματα

Δεδομένα από αισθητήρες για διάφορα επίπεδα αυτονομίας (ADAS)

Έξυπνοι βοηθοί

Αναγνώριση ομιλίας και προσώπου (Siri, Alexa, Google Assistant)

Υγεία

Ανάλυση ιατρικών εικόνων (CT, MRI, υπέρηχοι), υποστήριξη διάγνωσης

Συστήματα συστάσεων

Διαφημίσεις και περιεχόμενο που «μαντεύουν» τις προτιμήσεις μας

Ρομπότ

Μεγαλύτερη αυτονομία μέσω όρασης, γλώσσας και ενισχυτικής μάθησης

Χρηματοοικονομικά

Chatbots, αυτοματοποιημένες επενδύσεις, πρόβλεψη τάσεων

Πρόβλεψη κυκλοφορίας

Πλοήγηση σε πραγματικό χρόνο (π.χ. Google Maps)

Βασική Πηγή: Liu, Z. (2025). *Artificial Intelligence for Engineers*.

Η ΤΝ σήμερα σε αριθμούς

Η ΤΝ θεωρείται ο πυρήνας της 4ης βιομηχανικής επανάστασης (Industry 4.0)
Από το ChatGPT μέχρι τα αυτόνομα οχήματα: μεγαλύτερη αποδοτικότητα, πιο «έξυπνα» προϊόντα, λιγότερες επαναλαμβανόμενες εργασίες.

+38%
κερδοφορία 16 κλάδων σε 12 οικονομίες έως το 2035 (εκτίμηση)

×2,7
Δημοσιεύσεις ΤΝ
88.000 (2010) → 240.000 (2022)

×30
Διπλώματα ευρεσιτεχνίας
αιτήσεις, 2015 → 2021

189 δισ. $
Επενδύσεις σε ΤΝ (2023)
+1300% σε σχέση με το 2013

Επιπτώσεις σε πολλούς τομείς

Οικονομία & εργασία
Νέες θέσεις εργασίας και αυξημένη ζήτηση για γνώσεις ΤΝ

Κινητικότητα
Εκτιμώμενη μείωση οδικών ατυχημάτων έως 90%

Υγεία
Θεραπείες, φροντίδα σε απομακρυσμένες περιοχές

Ασφάλεια
Πρόληψη κυβερνοεπιθέσεων με ζημιές >50 δισ. $

Βασική Πηγή: Liu, Z. (2025). *Artificial Intelligence for Engineers*.

Δεδομένα στη Μηχανική και τα Υλικά

Η ΤΝ **«τρέφεται» με δεδομένα**. Τα μεγάλα σύνολα δεδομένων επιτρέπουν πιο σύνθετα μοντέλα, με μεγαλύτερη χωρητικότητα και **καλύτερη γενίκευση**.

Πηγές δεδομένων στη μηχανική

- **Φθηνές φορητές συσκευές με αισθητήρες**
- **Τηλεπισκόπηση**
- **Αρχεία καταγραφής λογισμικού**
- **Κάμερες & μικρόφωνα**
- **Αναγνώστες RFID**
- **Ασύρματα δίκτυα αισθητήρων**

Δεδομένα στα (βιο)υλικά

- **Μετρήσεις:** μηχανικές δοκιμές, ρυθμός αποδόμησης
- **Εικόνες:** SEM, μικροσκοπία, ιστολογικές τομές
- **Φάσματα:** XRD, FTIR, καμπύλες τάσης–παραμόρφωσης
- **Βιολογικές δοκιμές:** κυτταροτοξικότητα, βιωσιμότητα κυττάρων
- **Προσομοιώσεις:** πεπερασμένα στοιχεία, μοριακή δυναμική
- **Διεργασία:** σύσταση, παράμετροι 3D εκτύπωσης

Πρόκληση: τα δεδομένα στα υλικά είναι συχνά **λίγα, ετερογενή, ελλιπή** και **ακριβά** στην απόκτηση (κάθε δείγμα απαιτεί παρασκευή και μέτρηση). Γι' αυτό η **ποιότητα** των δεδομένων είναι κρίσιμη.

Βασική Πηγή: Liu, Z. (2025). *Artificial Intelligence for Engineers*.



Ενότητα 2

Θεμελιώδεις Έννοιες της Τεχνητής Νοημοσύνης

Ορισμός και βασικά χαρακτηριστικά

Η **Τεχνητή Νοημοσύνη (ΤΝ)** είναι μια μέθοδος (ή η χρήση μιας μεθόδου) που επιτρέπει σε έναν υπολογιστή ή σε έναν πράκτορα που ελέγχεται από υπολογιστή, είτε υλικό (π.χ. ρομπότ), είτε λογισμικό (π.χ. πρόγραμμα), να **«σκέφτεται» ευφυώς, όπως ο ανθρώπινος νους**.

Επιτυγχάνεται μελετώντας τον τρόπο λειτουργίας του εγκεφάλου και αναλύοντας τις γνωστικές διεργασίες.

Τα «προϊόντα» της ΤΝ:

- **Δεδομένα**
- **Αλγόριθμοι**
- **Ευφυές λογισμικό & συστήματα**
- **Πρότυπα για εφαρμογές**

Γενική ΤΝ (General AI / Strong AI)

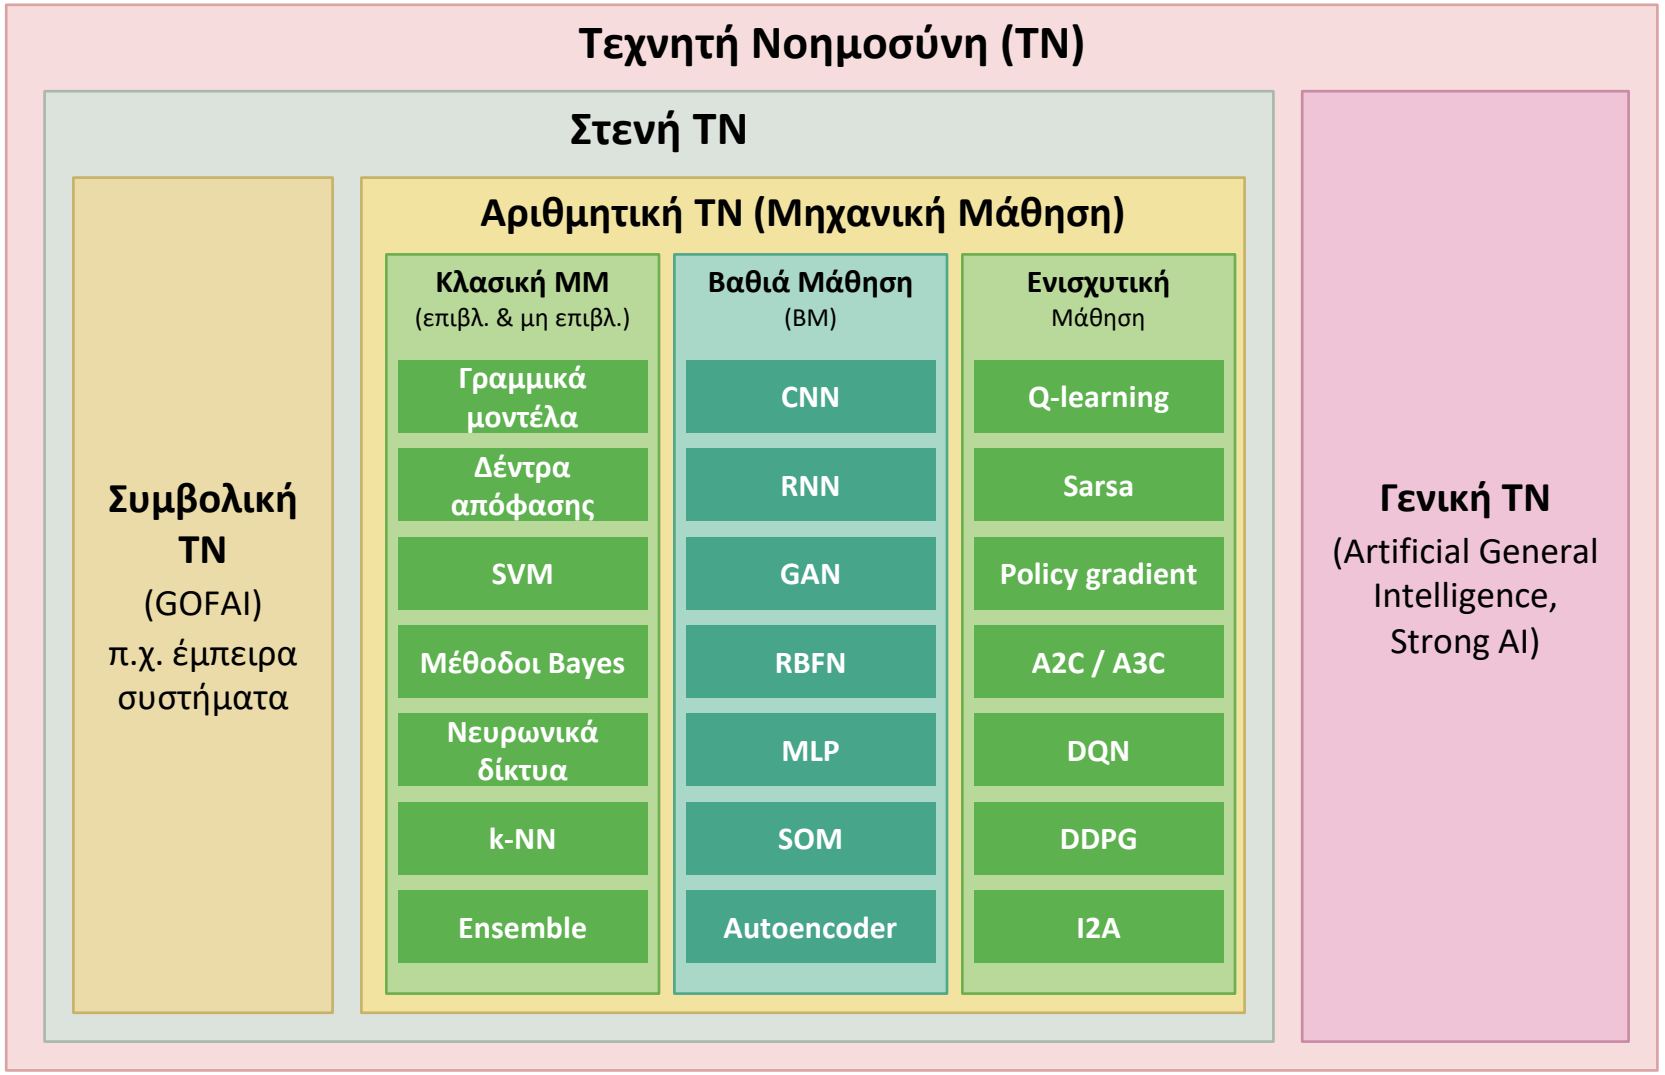
- Ευφυείς πράκτορες που χειρίζονται πολύ **διαφορετικές** εργασίες.
- Παραμένει μακρινός στόχος, αν και συζητείται ξανά σήμερα ως «τεχνητή γενική νοημοσύνη» (AGI).

Στενή ΤΝ (Narrow AI)

- Στοχεύει σε **συγκεκριμένες, πιο εφικτές εργασίες**.
- Εδώ βρίσκεται σχεδόν όλη η πρακτική πρόοδος. Οι επιτυχίες της στενής ΤΝ τροφοδοτούν την αναζήτηση της γενικής.
- Π.χ. ένα μοντέλο που προβλέπει τον ρυθμό αποδόμησης ενός εμφυτεύματος.

Βασική Πηγή: Liu, Z. (2025). *Artificial Intelligence for Engineers*.

ΤΝ, Μηχανική Μάθηση και Βαθιά Μάθηση



Πώς σχετίζονται;

- **ΤΝ:** το ευρύ πεδίο, χωρίζεται σε **στενή** και **γενική** ΤΝ.
- Η στενή ΤΝ χωρίζεται σε **συμβολική** (λογικοί κανόνες) και **αριθμητική** ΤΝ.
- **Μηχανική Μάθηση (ΜΜ)** = αριθμητική ΤΝ: μαθαίνει από δεδομένα.
- **Βαθιά Μάθηση (ΒΜ) :** υποσύνολο της ΜΜ με νευρωνικά δίκτυα πολλών επιπέδων.
- Στην πράξη, οι όροι ΤΝ και ΜΜ χρησιμοποιούνται συχνά ως συνώνυμοι.

Βασική Πηγή: Liu, Z. (2025). *Artificial Intelligence for Engineers*.

Η έννοια της Μηχανικής Μάθησης

Η Μηχανική Μάθηση μαθαίνει από δεδομένα: το μοντέλο κατασκευάζεται από τα δεδομένα, κατά την ανάλυση. Η διαδικασία αυτή ονομάζεται εκπαίδευση (training).

Δύο τρόποι απόκτησης γνώσης

Παραγωγή (deduction)	Επαγωγή (induction)
Συμβολική ΤΝ	***Μηχανική Μάθηση***
Γενικοί κανόνες	**Ειδικές παρατηρήσεις**
↓	↓
Ειδικό συμπέρασμα	**Γενικό μοντέλο**

Τι χρειάζεται για να φτιάξουμε ένα μοντέλο;



Δεδομένα	Αλγόριθμος	Μοντέλο
+ προκαθορισμένη γνώση (ετικέτες, μετρικές ή ανταμοιβές)	ο τρόπος κατασκευής του μοντέλου	η γνώση που εξάγεται από τα δεδομένα

Οι αλγόριθμοι καθορίζουν πώς τα δεδομένα γίνονται μοντέλα, γι' αυτό η ΜΜ παρουσιάζεται συνήθως μέσα από τους αλγορίθμους της. Μετά την εκπαίδευση, το μοντέλο εφαρμόζεται σε νέα δεδομένα (έλεγχος / πρόβλεψη).

Βασική Πηγή: Liu, Z. (2025). *Artificial Intelligence for Engineers*.

Μαθηματική Αναπαράσταση

Από μαθηματική σκοπιά, τα περισσότερα προβλήματα μηχανικής ανάγονται στην **εύρεση μιας απεικόνισης f** από την **είσοδο x** στην **έξοδο y**.

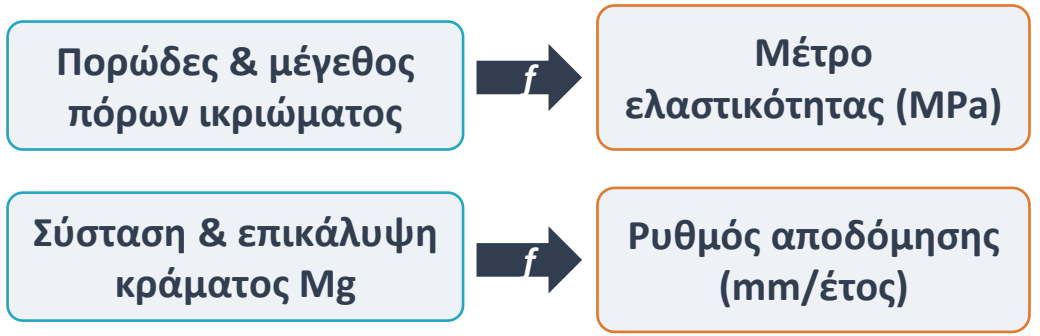


$$y = f(x)$$

Τα μοντέλα ως μαθηματικές συναρτήσεις

- Τα μοντέλα ΜΜ είναι **μαθηματικές συναρτήσεις** (π.χ. πολυώνυμα ή εξισώσεις γραμμικής άλγεβρας με πίνακες), που επεξεργάζεται εύκολα ο υπολογιστής.
- Συχνά λέγονται **προσεγγίσεις συναρτήσεων** (function approximations), γιατί η ακριβής f είναι δύσκολο να βρεθεί.

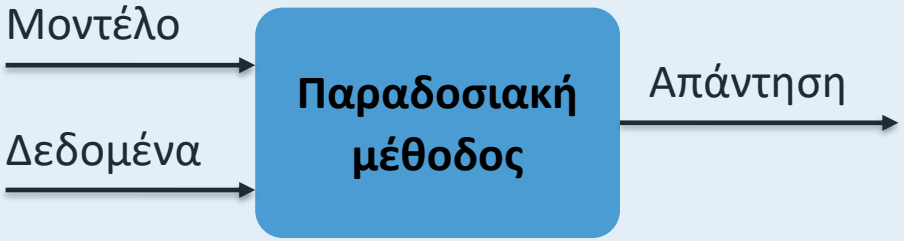
Παραδείγματα από βιοϋλικά



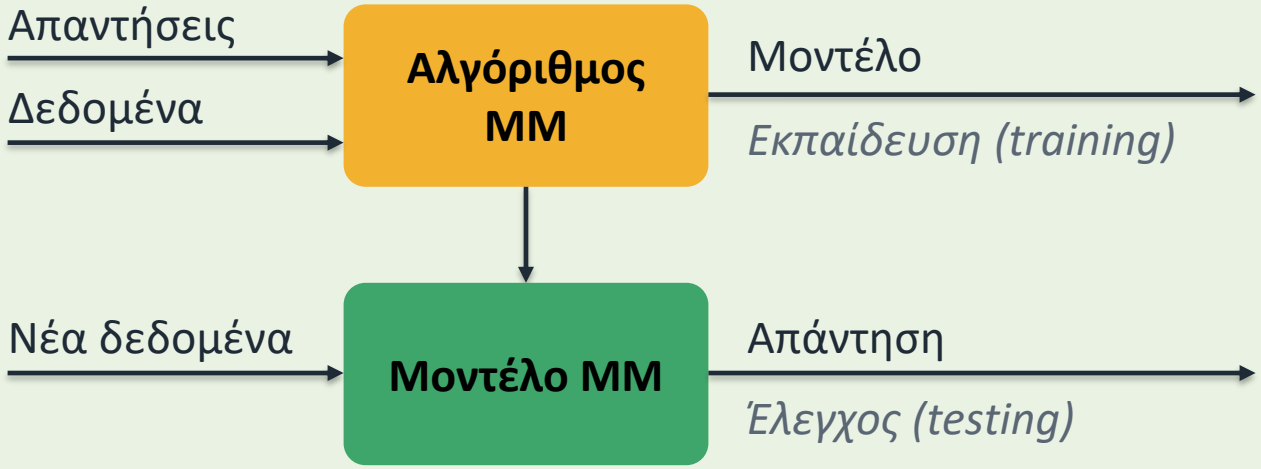
Βασική Πηγή: Liu, Z. (2025). *Artificial Intelligence for Engineers*.

Υπολογιστικές Προσεγγίσεις

Physics-based (παραδοσιακή)



Data-driven (Μηχανική Μάθηση)



Physics-based

Το μοντέλο φτιάχνεται **πριν** την ανάλυση, από τους νόμους της φυσικής (αναλυτικές λύσεις ή αριθμητικές μέθοδοι, π.χ. FEM). Μετά τροφοδοτείται με δεδομένα για να δώσει απάντηση.

Data-driven

Το μοντέλο φτιάχνεται **κατά** την ανάλυση, από τα δεδομένα (εκπαίδευση). Μετά εφαρμόζεται σε νέα δεδομένα, όπως η παραδοσιακή μέθοδος.

Η επιλογή μεθόδου εξαρτάται από την **πολυπλοκότητα** του προβλήματος, τη **γνώση της φυσικής**, την **υπολογιστική ισχύ** και τις απαιτήσεις **χρόνου και ακρίβειας**.

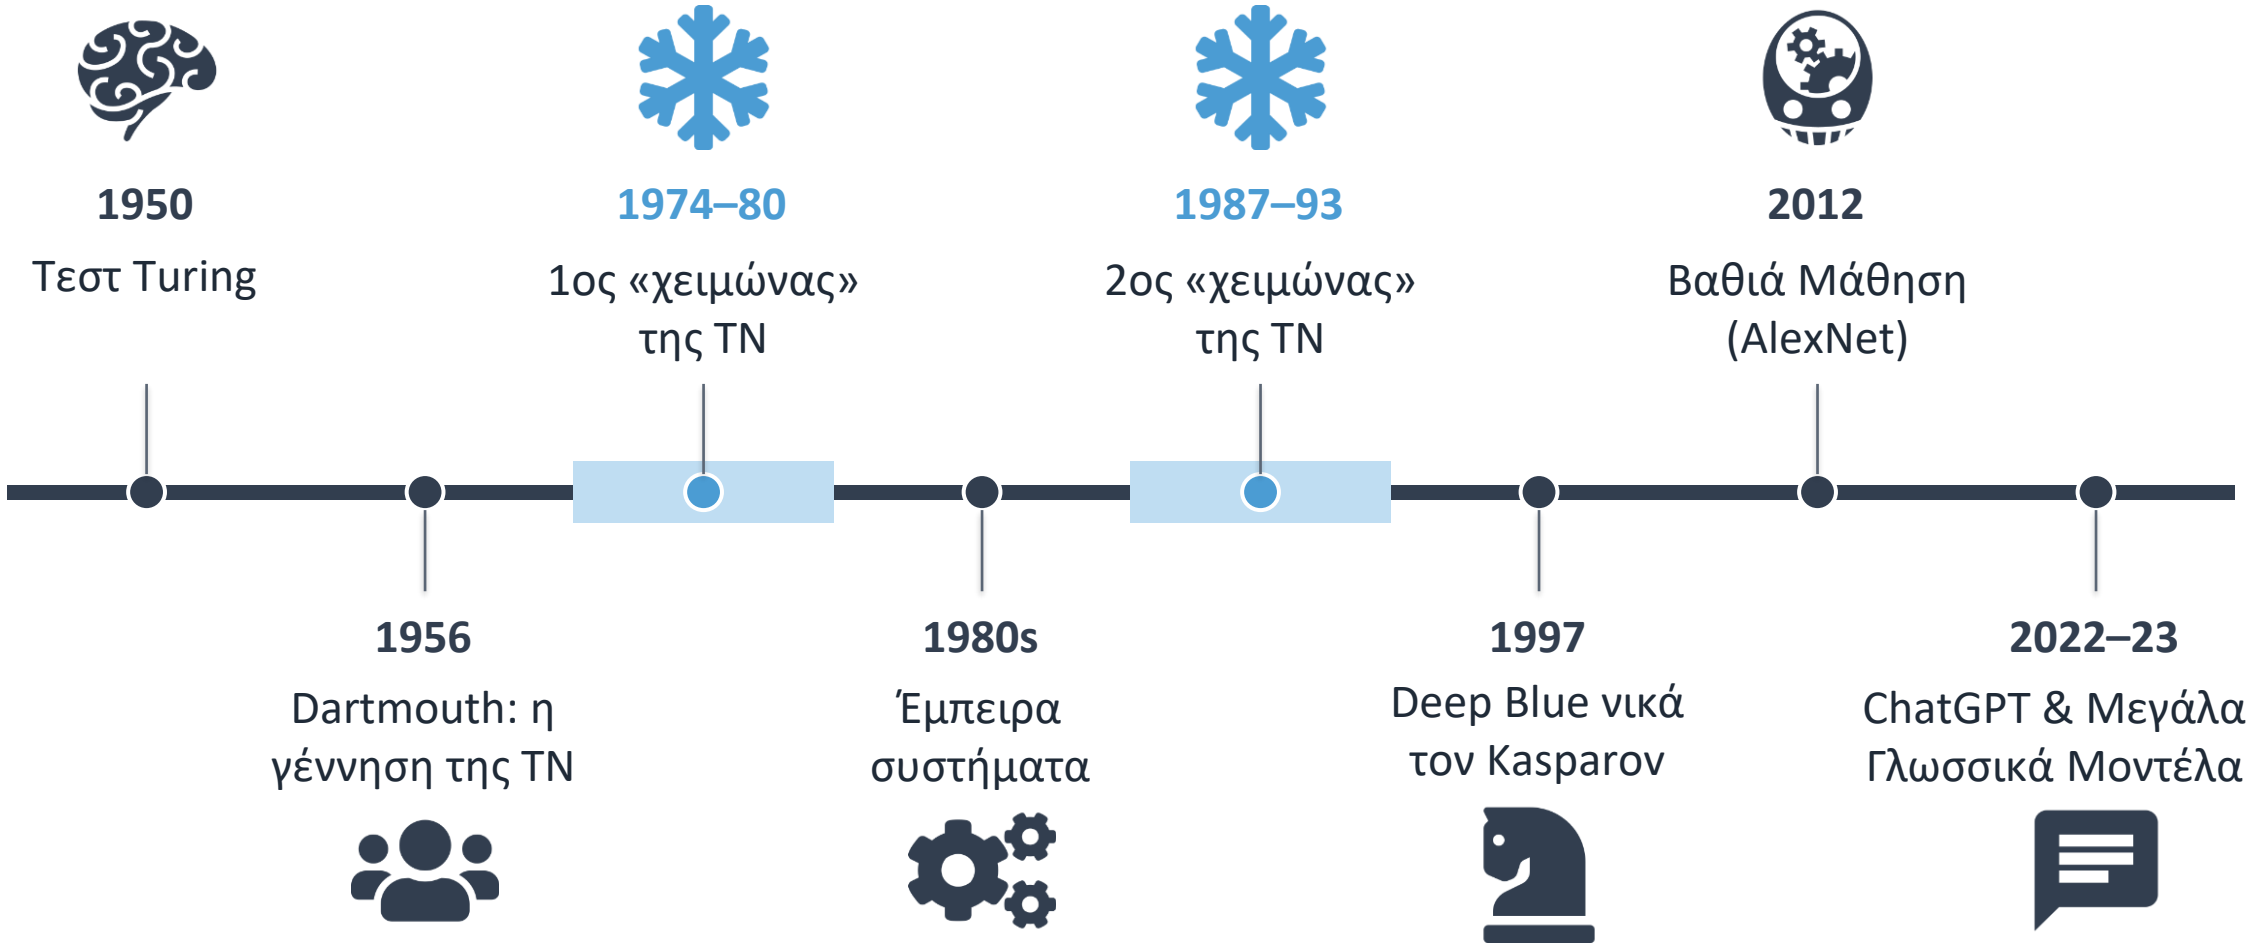
Βασική Πηγή: Liu, Z. (2025). *Artificial Intelligence for Engineers*.



Ενότητα 3

Ιστορική Εξέλιξη και Σύγχρονη Ανάπτυξη

Ιστορική Εξέλιξη της ΤΝ



Μοτίβο: Υπεραισιοδοξία → Ανεκπλήρωτες υποσχέσεις → «Χειμώνας» → Νέα ανάκαμψη

Βασική Πηγή: Liu, Z. (2025). *Artificial Intelligence for Engineers*.

Συμβολική και Αριθμητική ΤΝ

Συμβολική ΤΝ
«Good Old-Fashioned AI» (GOFAI)

- Γνώση σε μορφή **λογικών κανόνων** (π.χ. εντολές «if»), κατανοητών από τον άνθρωπο
- **Παραγωγή:** από το γενικό στο ειδικό
- Κυριάρχησε στα πρώτα χρόνια (1956–74) και με τα **έμπειρα συστήματα** (1980s)
- Όριο: οι κανόνες πρέπει να οριστούν από ανθρώπους

Αριθμητική ΤΝ
Μηχανική Μάθηση

- Γνώση που **μαθαίνεται από δεδομένα**
- **Επαγωγή:** από το ειδικό στο γενικό
- Πέρασε «χειμώνες» (π.χ. νευρωνικά δίκτυα στα 1970s) αλλά **κυριαρχεί σήμερα**
- Όριο: εξαρτάται από την ποσότητα και την ποιότητα των δεδομένων

Οι «πέντε σχολές» της Μηχανικής Μάθησης (με βάση τον μηχανισμό μάθησης)

Συμβολισμός	Συνδεσιονισμός	Μπεϋζιανισμός	Εξελικτισμός	Αναλογισμός
σύμβολα + λογική + δεδομένα	*μίμηση του εγκεφάλου*	*πιθανοτική συλλογιστική*	*μίμηση της εξέλιξης*	*ομοιότητα μεταξύ δειγμάτων*
Δέντρα απόφασης, random forests	**Νευρωνικά δίκτυα, βαθιά μάθηση**	**Naive Bayes, δίκτυα Bayes, HMM**	**Γενετικοί αλγόριθμοι**	**k-NN, SVM**

Βασική Πηγή: Liu, Z. (2025). *Artificial Intelligence for Engineers*.

Ανάπτυξη της Βαθιάς Μάθησης

Το **«τρίτο κύμα»** της ΤΝ (2011–σήμερα) βασίζεται στη **Βαθιά Μάθηση** και την **Ενισχυτική Μάθηση**. Τροφοδοτείται από τρεις παράγοντες:

Μεγάλα δεδομένα

- Big data από αισθητήρες και διαδίκτυο
- ImageNet: 14 εκατ. επισημασμένες εικόνες

Υπολογιστική ισχύς

- Εκπαίδευση βαθιών δικτύων σε GPU
- Παράλληλος υπολογισμός

Καλύτεροι αλγόριθμοι

- Λύση στο vanishing gradient (ReLU)
- CNN, LSTM, transformers

6 min → 13 s — Χρόνος εκπαίδευσης ίδιου συστήματος (2018 → 2021)

–70% / έτος — Κόστος εκπαίδευσης (2024), ταχύτερα από τον νόμο του Moore

Ορόσημα

2006	2009	2012	2014	2016	2020+
Deep belief networks	Βάση ImageNet	AlexNet κερδίζει το ImageNet	GAN	Βαθιά ενισχυτική μάθηση (AlphaGo)	LLMs & γενετική ΤΝ

Επιτυχίες: **όραση υπολογιστών** (CNN) · **επεξεργασία φυσικής γλώσσας** (LSTM, transformers) · **ενισχυτική μάθηση** σε παιχνίδια και ρομποτική

Βασική Πηγή: Liu, Z. (2025). *Artificial Intelligence for Engineers*.

Ενσωμάτωση της ΤΝ στη σύγχρονη Μηχανική

Ανάλυση βασισμένη στη φυσική
Multiphysics · Multiscale · Multi-fidelity
→ *τάση για συνεργασία μεθόδων*

+

Ανάλυση με ΤΝ
Βαθιά μάθηση · Ενισχυτική μάθηση
→ *τάση για αυτοματοποίηση*

Οι δύο τάσεις είναι **συμπληρωματικές** και καλύπτουν την ανάγκη για πιο σύνθετη και ακριβή ανάλυση

Πώς αλλάζει η μηχανική πρακτική

Παραδοσιακά	Με ΤΝ
Χειροκίνητη επεξεργασία μετρήσεων, εικόνων, σχεδίων	**Αυτόματη ανάλυση, ακόμα και ακατέργαστων δεδομένων**
Διαχείριση με υποκειμενική κρίση	**Αποφάσεις με βάση τα δεδομένα**
Δύσκολη πρόβλεψη υπό αβεβαιότητα	**Μοντέλα που μαθαίνουν από προηγούμενα δεδομένα**
Χρόνος σε επαναλαμβανόμενη εργασία	**Παραγωγικότητα, αντικειμενικότητα, ακρίβεια**

Παράδειγμα: Αυτόνομη Οδήγηση

- **Ανάλυση εικόνας δρόμου**
- **Σχεδιασμός διαδρομής**
- **Έλεγχος οχήματος**
- **Διαχείριση ενέργειας**
- **Ανίχνευση αντικειμένων**
- **Αντίδραση σε έκτακτα**

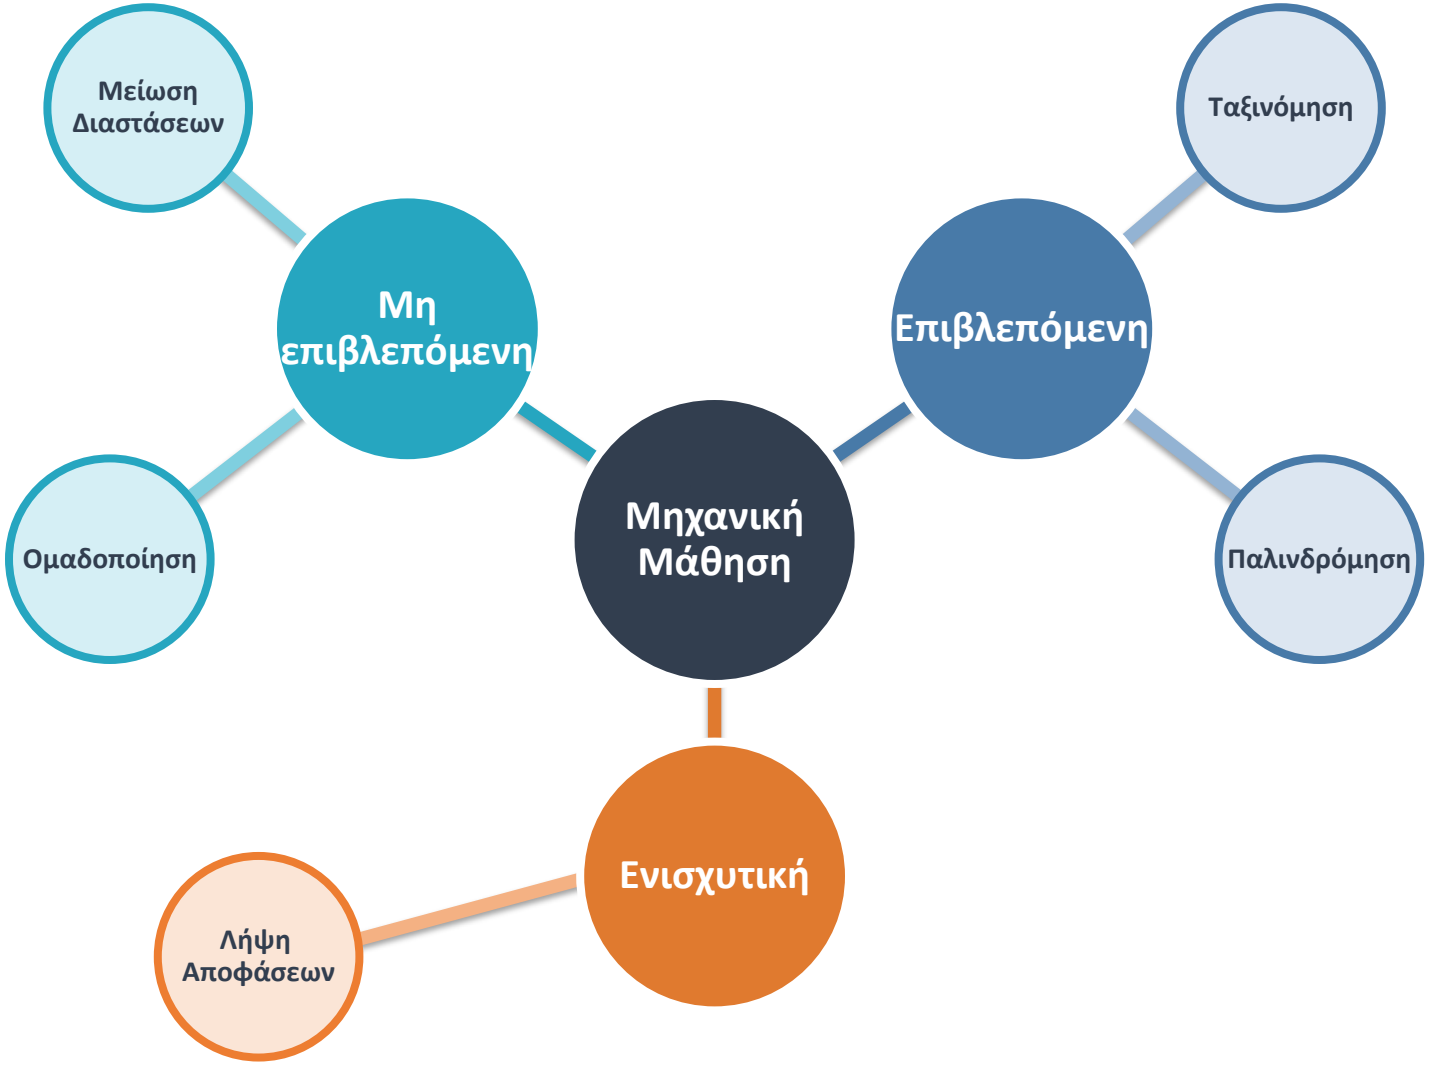
Βασική Πηγή: Liu, Z. (2025). *Artificial Intelligence for Engineers*.



Ενότητα 4

Βασικές Κατηγορίες και Εργασίες Μηχανικής Μάθησης

Κατηγορίες της Μηχανικής Μάθησης



Επιβλεπόμενη Μάθηση – Supervised Learning

Το μοντέλο εκπαιδεύεται με παραδείγματα για τα οποία γνωρίζουμε τη σωστή απάντηση. Για κάθε είσοδο δίνεται και η επιθυμητή έξοδος (ετικέτα).

Μη Επιβλεπόμενη Μάθηση – Unsupervised Learning

Το μοντέλο λαμβάνει μόνο δεδομένα εισόδου, χωρίς ετικέτες, και αναζητά μόνο του δομή ή μοτίβα σε αυτά.

Ενισχυτική Μάθηση – Reinforcement Learning

Δεν υπάρχουν έτοιμα δεδομένα εκπαίδευσης. Το μοντέλο μαθαίνει μέσω δοκιμής και σφάλματος: λαμβάνει ανταμοιβή ή ποινή ανάλογα με τις ενέργειές του.

Ημι-Επιβλεπόμενη – Semi-Supervised: Συνδυάζει λίγα δεδομένα με ετικέτες και πολλά χωρίς. Είναι χρήσιμη όταν η επισήμανση των δεδομένων είναι δαπανηρή.

Βασική Πηγή: Liu, Z. (2025). *Artificial Intelligence for Engineers*.

Επιβλεπόμενη Μάθηση (Supervised)

Το μοντέλο μαθαίνει από ζεύγη **(είσοδος x, έξοδος y)** και στη συνέχεια προβλέπει την έξοδο για νέα δείγματα.

Ταξινόμηση (Classification)

Χρησιμοποιείται για την πρόβλεψη **διακριτών** τιμών (κατηγοριών).

Παραδείγματα:

- Είναι το κεραμικό «βιοενεργό» ή «βιοαδρανές»;
- Τι ιστός αναπτύσσεται γύρω από το εμφύτευμα (οστό ή ινώδης ιστός);

Αλγόριθμοι: Λογιστική Παλινδρόμηση, δέντρα, SVM, k-NN, CNN

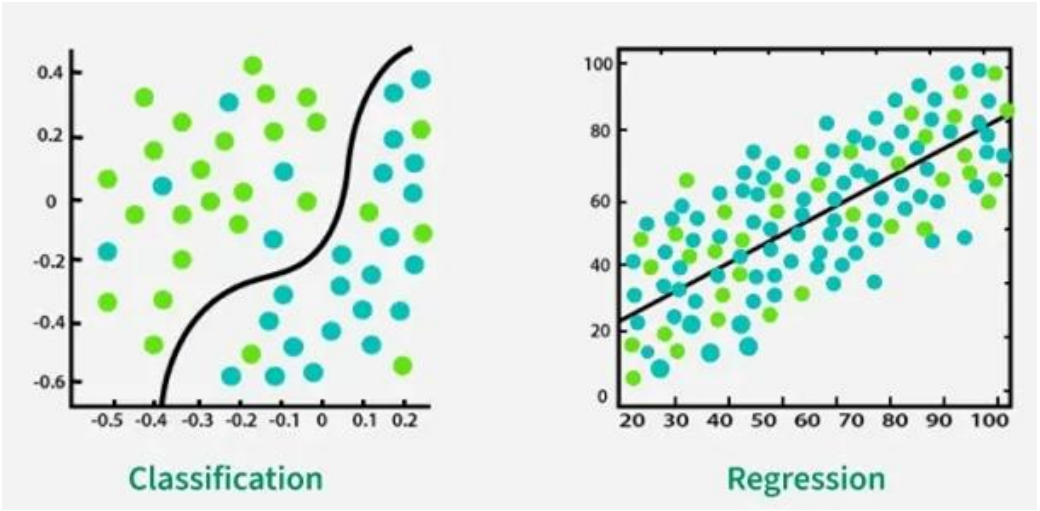
Παλινδρόμηση (Regression)

Χρησιμοποιείται για την πρόβλεψη συνεχών τιμών.

Παραδείγματα:

- Ποσοστό φαρμάκου που αποδεσμεύεται σε 24 ώρες (%);
- Ρυθμός αποδόμησης κράματος Mg (mm/έτος);

Αλγόριθμοι: Γραμμικά μοντέλα, Ridge/Lasso, δέντρα, SVR, νευρωνικά

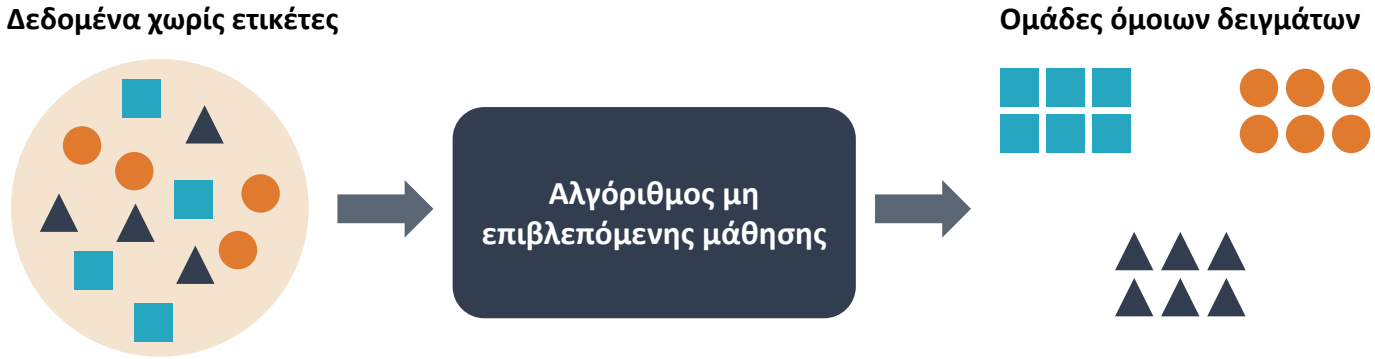


Βασική Πηγή: Liu, Z. (2025). *Artificial Intelligence for Engineers*.

Μη Επιβλεπόμενη Μάθηση (Unsupervised)

Εντοπίζει δομή και μοτίβα χρησιμοποιώντας **μόνο δεδομένα εισόδου**, χωρίς ετικέτες.

Το μοντέλο αναλύει τις σχέσεις μεταξύ των δειγμάτων (π.χ. τις αποστάσεις τους).



Ομαδοποίηση (Clustering)

Χρησιμοποιείται για τον χωρισμό των δεδομένων σε **ομάδες όμοιων δειγμάτων**.

Αλγόριθμοι: K-Means, DBSCAN, GMM, ιεραρχική
Παράδειγμα: Βιοϋλικά με παρόμοια συμπεριφορά σε κυτταροκαλλιέργεια

Μείωση διαστάσεων (Dimensionality Reduction)

Χρησιμοποιείται για τη **μείωση του αριθμού των χαρακτηριστικών**, διατηρώντας την ουσιώδη πληροφορία.

Αλγόριθμοι: PCA, LDA, ICA, Isomap
Παράδειγμα: Οπτικοποίηση σε 2D εμφυτευμάτων με δεκάδες ιδιότητες

Ανίχνευση Ανωμαλιών (Anomaly Detection)

Χρησιμοποιείται για τον εντοπισμό **σπάνιων δειγμάτων** που αποκλίνουν από τα υπόλοιπα.

Αλγόριθμοι: One-class SVM, autoencoders, GMM
Παράδειγμα: Ελαττωματικά εμφυτεύματα στη γραμμή παραγωγής

Κανόνες Συσχέτισης (Association Rules)

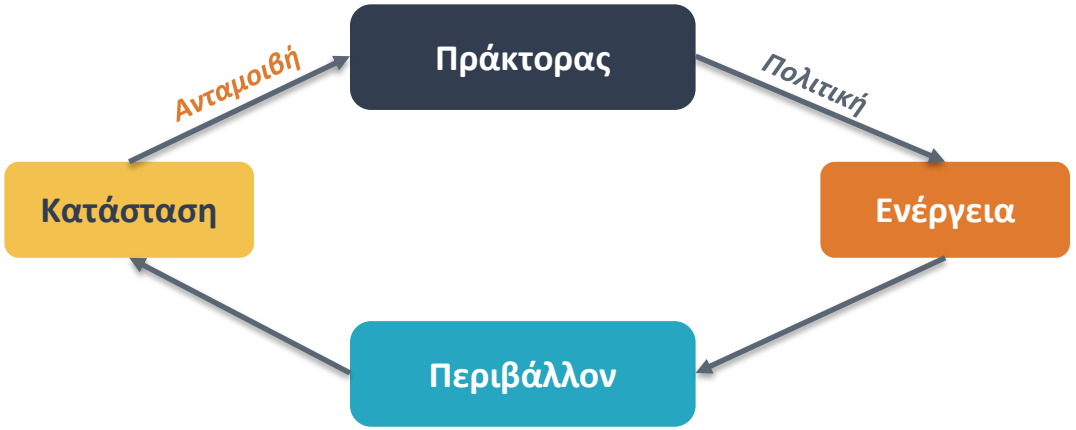
Χρησιμοποιείται για την ανακάλυψη **σχέσεων μεταξύ μεταβλητών**, στη μορφή «αν Α, τότε Β».

Αλγόριθμοι: Apriori, FP-growth, Eclat
Παράδειγμα: «Υψηλή τραχύτητα αυξημένη προσκόλληση κυττάρων»

Βασική Πηγή: Liu, Z. (2025). *Artificial Intelligence for Engineers*.

Ενισχυτική Μάθηση (Reinforcement)

Δεν δίνονται έτοιμα δεδομένα. Ο αλγόριθμος **παράγει μόνος του τα δεδομένα** αλληλεπιδρώντας με το περιβάλλον και μαθαίνει με **δοκιμή και σφάλμα** ποιες ενέργειες δίνουν τη μεγαλύτερη ανταμοιβή.



Βασικά στοιχεία

- **Πράκτορας (agent):** αυτός που μαθαίνει και παίρνει αποφάσεις.
- **Περιβάλλον (environment):** ο «κόσμος» στον οποίο δρα ο πράκτορας.
- **Ενέργεια & ανταμοιβή:** ο πράκτορας δρα και λαμβάνει ανταμοιβή ή ποινή.
- **Στόχος: η καλύτερη πολιτική (policy):** ποια ενέργεια επιλέγεται σε κάθε κατάσταση, ώστε να μεγιστοποιείται η συνολική ανταμοιβή.

Βασισμένοι σε τιμές (value-based)

Μαθαίνουν πόσο «αξίζει» κάθε ενέργεια σε κάθε κατάσταση (πίνακας Q).

Αλγόριθμοι: Q-learning, Sarsa

Βασισμένοι σε πολιτική (policy-based)

Μαθαίνουν απευθείας την πιθανότητα επιλογής κάθε ενέργειας.

Αλγόριθμοι: Policy gradient

Υβριδικοί (actor-critic)

Ο ένας αλγόριθμος επιλέγει την ενέργεια και ο άλλος την αξιολογεί.

Αλγόριθμοι: Actor-critic, A3C

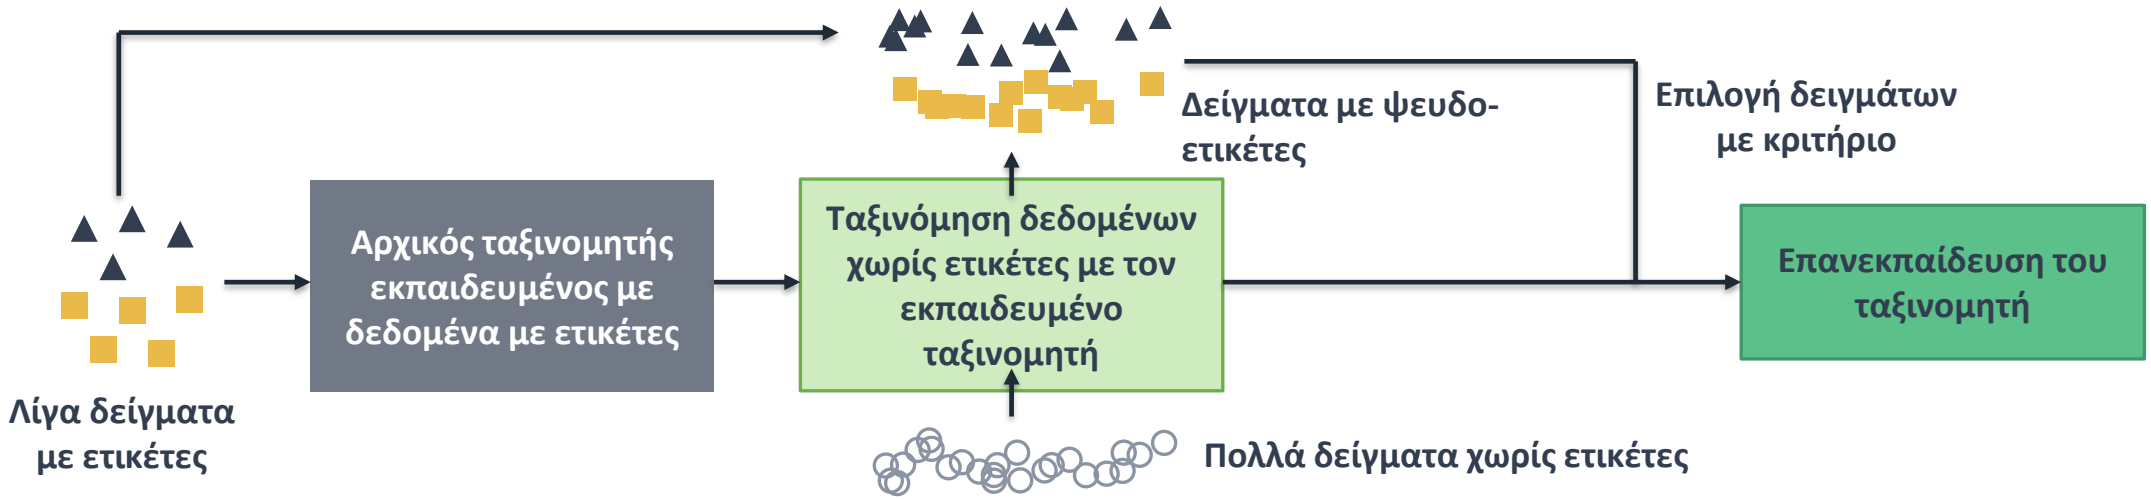
Εφαρμογές: ρομποτική, παιχνίδια (σκάκι, Go), πλοήγηση, έλεγχος διεργασιών

Βασική Πηγή: Liu, Z. (2025). *Artificial Intelligence for Engineers*.

Ημι-Επιβλεπόμενη Μάθηση (Semi-Supervised)

Συνδυάζει **λίγα δεδομένα με ετικέτες** και **πολλά δεδομένα χωρίς ετικέτες**. Είναι «υβρίδιο» επιβλεπόμενης και μη επιβλεπόμενης μάθησης, αλλά χρησιμοποιείται κυρίως για τους ίδιους σκοπούς με την επιβλεπόμενη (ταξινόμηση, παλινδρόμηση).

Πότε χρησιμοποιείται;
Όταν η επισήμανση των δεδομένων είναι δαπανηρή ή χρονοβόρα.



Πλεονεκτήματα	Απαιτήσεις	Παραλλαγές
• Λιγότερη προσπάθεια επισήμανσης • Μικρότερη μεροληψία από την επισήμανση	• Ακριβείς ετικέτες στα λίγα δεδομένα • Ισορροπία κλάσεων στα δεδομένα χωρίς ετικέτες	• Self-training, co-training • Label propagation, semi-supervised SVM, ημι-επιβλεπόμενη βαθιά μάθηση

Βασική Πηγή: Liu, Z. (2025). *Artificial Intelligence for Engineers*.

Αντιστοίχιση προβλημάτων σε εργασίες ML

Προβλήματα	Τύπος εξόδου	Εργασία ML	Κατηγορία
Ρυθμός αποδόμησης κράματος Mg για εμφύτευμα	Συνεχής αριθμός	**Παλινδρόμηση**	**Επιβλεπόμενη**
Είναι το υλικό κυτταροτοξικό ή όχι;	Κατηγορία (ναι / όχι)	**Ταξινόμηση**	**Επιβλεπόμενη**
Ομάδες βιοϋλικών με παρόμοια απόκριση κυττάρων	Ομάδες (χωρίς ετικέτα)	**Ομαδοποίηση**	**Μη επιβλεπόμενη**
Ελαττωματικά εμφυτεύματα στη γραμμή παραγωγής	Βαθμός / ένδειξη ανωμαλίας	**Ανίχνευση ανωμαλιών**	**Μη επιβλεπόμενη**
Οπτικοποίηση ικριωμάτων με δεκάδες ιδιότητες	Λίγες νέες διαστάσεις	**Μείωση διαστάσεων**	**Μη επιβλεπόμενη**
Ιστολογικές εικόνες: λίγες σχολιασμένες, πολλές όχι	Κατηγορία ιστού	**Ταξινόμηση**	**Ημι-επιβλεπόμενη**
Βέλτιστες παράμετροι 3D εκτύπωσης ικριώματος	Πολιτική / ακολουθία ενεργειών	**Λήψη αποφάσεων**	**Ενισχυτική**

Βασική Πηγή: Liu, Z. (2025). *Artificial Intelligence for Engineers*.



Ενότητα 5

Δεδομένα, Αναπαράσταση και Μοντέλα Μηχανικής Μάθησης

Βασική ορολογία δεδομένων

Δεδομένα (Data): βασική πηγή πληροφορίας από την οποία ένα μοντέλο Μηχανικής Μάθησης μαθαίνει. Περιλαμβάνουν αριθμούς, σύμβολα, παρατηρήσεις ή μετρήσεις που χρησιμοποιούνται για την περιγραφή ενός προβλήματος ή ενός πραγματικού συστήματος. Στην επιβλεπόμενη μάθηση, τα δεδομένα διακρίνονται σε **εισόδους (inputs)** και **εξόδους (outputs)**.

Σύνολο δεδομένων (Dataset): οργανωμένη συλλογή πολλών παρατηρήσεων ή δειγμάτων που χρησιμοποιούνται για συγκεκριμένο σκοπό, όπως η εκπαίδευση ή η αξιολόγηση ενός μοντέλου.

Χαρακτηριστικό (Feature): μετρήσιμη ή αριθμητικά αναπαριστώμενη ιδιότητα ενός δείγματος. Τα χαρακτηριστικά αποτελούν τις μεταβλητές εισόδου που χρησιμοποιεί το μοντέλο για να αναγνωρίσει σχέσεις και μοτίβα στα δεδομένα.

Sample	% C (wt%)	% Cr (wt%)	Θερμοκρασία κατεργασίας (°C)	Χρόνος (min)	Σκληρότητα (HV)
Υλικό 1	0.20	1.0	800	30	180
Υλικό 2	0.40	1.5	850	45	235
Υλικό 3	0.60	1.0	900	60	310
Υλικό 4	0.35	1.8	850	30	260
Υλικό 5	0.50	1.2	875	45	290

Ετικέτα (Label): τιμή ή κατηγορία που συνδέεται με ένα δείγμα και την οποία θέλουμε να μάθει να προβλέπει το μοντέλο. Αποτελεί την επιθυμητή **έξοδο (output)** σε ένα πρόβλημα επιβλεπόμενης μάθησης.

Δείγμα (Sample): μία μεμονωμένη παρατήρηση μέσα σε ένα dataset. Μπορεί να αντιστοιχεί σε ένα υλικό, ένα δοκίμιο, ένα πείραμα ή μία προσομοίωση και περιγράφεται μέσω ενός συνόλου χαρακτηριστικών.

Βασική Πηγή: Liu, Z. (2025). *Artificial Intelligence for Engineers*.

Δομή ενός συνόλου δεδομένων Επιστήμης Υλικών

Ένα **σύνολο δεδομένων (dataset)** στην Επιστήμη των Υλικών οργανώνεται συνήθως σε μορφή πίνακα:

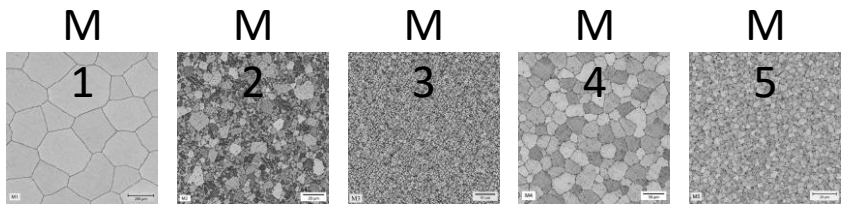
- Κάθε **γραμμή** αντιστοιχεί σε ένα **δείγμα (sample / data point)**, δηλαδή σε μία συγκεκριμένη παρατήρηση, μέτρηση ή πειραματική περίπτωση.
- Κάθε **στήλη** αντιστοιχεί σε ένα **χαρακτηριστικό (feature / attribute)**. Μπορεί να περιλαμβάνουν τη **χημική σύσταση**, τις **παραμέτρους κατεργασίας**, μικροδομικά χαρακτηριστικά και φυσικές ή μηχανικές ιδιότητες.
- Σε προβλήματα **επιβλεπόμενης μάθησης**, το dataset περιλαμβάνει μία ή περισσότερες **μεταβλητές-στόχους (label / target)**, π.χ. σκληρότητα ή αντοχή, ενώ όλα τα δείγματα διατηρούν **κοινή δομή και ίδιο αριθμό χαρακτηριστικών**.
- Το **Sample ID** χρησιμοποιείται για τη μοναδική αναγνώριση κάθε δείγματος. Μπορεί να αποθηκεύεται ρητά ή να προκύπτει έμμεσα από τη θέση ή τη σειρά της γραμμής στο dataset.

Ένα σύνολο δεδομένων με ***n*** δείγματα και ***p*** χαρακτηριστικά μπορεί να γραφεί ως:

$$X = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1p} \\ x_{21} & x_{22} & \cdots & x_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{np} \end{bmatrix} \qquad y = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix}$$

X: Πίνακας χαρακτηριστικών (είσοδος)
y: Διάνυσμα ετικετών (έξοδος)

	Χαρακτηριστικά (Features) Είσοδος				Ετικέτα (Label) Έξοδος
Sample ID	% C (wt%)	% Cr (wt%)	Θερμοκρασία κατεργασίας (°C)	Χρόνος (min)	Σκληρότητα (HV)
M1	0.20	1.0	800	30	180
M2	0.40	1.5	850	45	235
M3	0.60	1.0	900	60	310
M4	0.35	1.8	850	30	260
M5	0.50	1.2	875	45	290



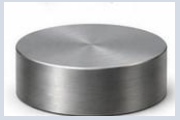
Από παρατηρήσεις σε αριθμητικά δεδομένα

Στη Μηχανική Μάθηση, ένα φυσικό αντικείμενο ή ένα πείραμα δεν μπορεί να χρησιμοποιηθεί απευθείας από το μοντέλο. Οι φυσικές παρατηρήσεις και οι μετρήσεις πρέπει πρώτα να μετατραπούν σε μία **αριθμητική αναπαράσταση**, κατάλληλη για επεξεργασία από έναν αλγόριθμο.

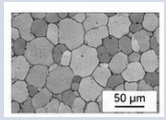
1

Φυσικό Σύστημα / Πείραμα

Ένα δείγμα υλικού χαρακτηρίζεται από συγκεκριμένη χημική σύσταση και συγκεκριμένες συνθήκες κατεργασίας.



Δείγμα Υλικού



Μικροδομή



Θερμική Κατεργασία



Μέτρηση Ιδιοτήτων (π.χ σκληρότητα)

2

Μετρήσεις / παρατηρήσεις

Από το υλικό ή το πείραμα προκύπτουν μετρήσιμες ποσότητες που περιγράφουν το δείγμα. Για παράδειγμα:

Χημική σύσταση:
$C = 0.4\ \text{wt.}\%, Cr = 1.5\ \text{wt.}\%$

Παράμετροι κατεργασίας:
$\mathrm{T} = 850°\mathrm{C}, \mathrm{t} = 45\ \mathrm{min}$

Μικροδομή:
$d = 14\,\mu m$

Μεταβλητή-στόχος:
$HV = 235$

3

Αριθμητική αναπαράσταση

Οι μεταβλητές που χρησιμοποιούνται ως είσοδοι οργανώνονται σε ένα **διάνυσμα χαρακτηριστικών**:

$\mathbf{x} = [0.40,\ 1.50,\ 850,\ 45,\ 14]$

Τα στοιχεία του **x** αντιστοιχούν, με καθορισμένη σειρά, στη σύσταση, στις παραμέτρους κατεργασίας και στη μικροδομή του δείγματος.

Για το συγκεκριμένο πρόβλημα επιβλεπόμενης μάθησης, η σκληρότητα αποτελεί την **ετικέτα / μεταβλητή-στόχο**:

$y = 235\ \mathrm{HV}$

4

Μοντέλο Μηχανικής Μάθησης

Κατά την εκπαίδευση, το μοντέλο λαμβάνει ζεύγη της μορφής:

$(\mathbf{x}_i, y_i)$

και προσαρμόζεται ώστε να περιγράφει τη σχέση μεταξύ των χαρακτηριστικών του υλικού και της ιδιότητας-στόχου. Για ένα νέο δείγμα με γνωστό διάνυσμα χαρακτηριστικών x, η πρόβλεψη εκφράζεται ως

$\hat{y} = f(\mathbf{x})$

Βασική Πηγή: Liu, Z. (2025). *Artificial Intelligence for Engineers*.

Διάκριση αλγορίθμου και μοντέλου

- **Αλγόριθμος (Algorithm)**: **η διαδικασία ή το σύνολο κανόνων** που καθορίζει τον τρόπο με τον οποίο τα δεδομένα χρησιμοποιούνται για την κατασκευή και την εκπαίδευση ενός μοντέλου. Καθορίζει τον τρόπο με τον οποίο πραγματοποιείται η **μάθηση από τα δεδομένα**, δηλαδή πώς προσαρμόζονται οι παράμετροι του μοντέλου ώστε να περιγράφεται όσο το δυνατόν καλύτερα η σχέση μεταξύ εισόδων και εξόδων. Παραδείγματα αλγορίθμων Μηχανικής Μάθησης αποτελούν η **γραμμική παλινδρόμηση**, τα **δένδρα απόφασης** και ο αλγόριθμος **k-means**.
- **Μοντέλο (Model): μαθηματική ή υπολογιστική αναπαράσταση** που προκύπτει από την εφαρμογή ενός αλγορίθμου στα δεδομένα. Μετά την εκπαίδευση, οι παράμετροι του μοντέλου έχουν προσδιοριστεί με βάση τα διαθέσιμα δεδομένα και επομένως το εκπαιδευμένο μοντέλο ενσωματώνει τη σχέση που έχει εξαχθεί από αυτά. Το εκπαιδευμένο μοντέλο μπορεί στη συνέχεια να χρησιμοποιηθεί για την **πρόβλεψη της εξόδου σε νέα, άγνωστα δεδομένα εισόδου**

Παράδειγμα στην Επιστήμη των Υλικών: Πρόβλεψη της σκληρότητας ενός κράματος από τη χημική σύσταση και τις παραμέτρους κατεργασίας.

Ως χαρακτηριστικά εισόδου μπορούν να χρησιμοποιηθούν, για παράδειγμα:

$$\mathbf{x} = [C,\ Cr,\ T,\ t]$$

όπου C και Cr είναι οι περιεκτικότητες των στοιχείων, T η θερμοκρασία κατεργασίας και t ο χρόνος κατεργασίας.
Ως μεταβλητή-στόχος χρησιμοποιείται η σκληρότητα:

$$y = HV$$

Για την περίπτωση της **γραμμικής παλινδρόμησης**, το μοντέλο μπορεί να έχει τη μορφή:

$$\hat{H} = \beta_0 + \beta_1 C + \beta_2 Cr + \beta_3 T + \beta_4 t$$

Οι συντελεστές:

$$\beta_0, \beta_1, \ldots, \beta_4$$

αποτελούν τις **παραμέτρους του μοντέλου** και προσδιορίζονται κατά την εκπαίδευση από τα διαθέσιμα δεδομένα.
Μετά τον προσδιορισμό τους, η εξίσωση αποτελεί το **εκπαιδευμένο μοντέλο** και μπορεί να χρησιμοποιηθεί για την πρόβλεψη της σκληρότητας νέων κραμάτων.

Βασική Πηγή: Liu, Z. (2025). *Artificial Intelligence for Engineers*.

Διαδικασία εκπαίδευσης μοντέλου

Η **εκπαίδευση (training)** είναι η διαδικασία κατά την οποία προσδιορίζονται ή προσαρμόζονται οι **παράμετροι του μοντέλου** με βάση τα διαθέσιμα δεδομένα. Στην επιβλεπόμενη μάθηση, το μοντέλο δέχεται τα χαρακτηριστικά εισόδου X και παράγει προβλέψεις $\hat{y}$, οι οποίες συγκρίνονται με τις πραγματικές τιμές y. Η διαφορά μεταξύ πρόβλεψης και πραγματικής τιμής αποτιμάται μέσω μιας **συνάρτησης απώλειας (loss function)**. Η εκπαίδευση αποσκοπεί στην εύρεση παραμέτρων που οδηγούν σε μικρότερη τιμή της συνάρτησης απώλειας.

Βασικά βήματα εκπαίδευσης

1. **Αρχικοποίηση**
   Καθορίζονται αρχικές τιμές για τις παραμέτρους του μοντέλου.
2. **Πρόβλεψη**
   Υπολογίζεται η έξοδος του μοντέλου από τα διαθέσιμα χαρακτηριστικά.
3. **Υπολογισμός απώλειας**
   Σύγκριση τιμής πρόβλεψης με πραγματικής μέσω της συνάρτησης απώλειας.
4. **Βελτιστοποίηση**
   Οι παράμετροι προσαρμόζονται με στόχο τη μείωση της απώλειας.

Η διαδικασία **πρόβλεψη → υπολογισμός απώλειας → ενημέρωση παραμέτρων** επαναλαμβάνεται κατά την εκπαίδευση.

Βασικό συμπέρασμα
Η εκπαίδευση είναι η διαδικασία προσδιορισμού των παραμέτρων του μοντέλου ώστε η απόκλιση μεταξύ των προβλέψεων και των δεδομένων εκπαίδευσης να περιορίζεται σύμφωνα με την επιλεγμένη συνάρτηση απώλειας.

Βασική Πηγή: Liu, Z. (2025). *Artificial Intelligence for Engineers*.

Αναπαράσταση – Βελτιστοποίηση – Αξιολόγηση

Η ανάπτυξη ενός μοντέλου Μηχανικής Μάθησης μπορεί να περιγραφεί μέσα από τρία αλληλένδετα στοιχεία: **πώς αναπαριστούμε το πρόβλημα, πώς μαθαίνουμε το μοντέλο και πώς αξιολογούμε την απόδοσή του**.

1 Αναπαράσταση (Representation)

Τα δεδομένα περιγράφονται μέσω **εισόδων και εξόδων**, ενώ επιλέγονται ο κατάλληλος **αλγόριθμος** και η μορφή του **μοντέλου**.
Το μοντέλο χαρακτηρίζεται από **παραμέτρους**, οι οποίες προσδιορίζονται από τα δεδομένα, και από **υπερπαραμέτρους**, οι οποίες καθορίζουν τον τρόπο με τον οποίο πραγματοποιείται η μάθηση.

2 Λύση / Βελτιστοποίηση (Solution / Optimization)

Κατά την εκπαίδευση αναζητούνται οι τιμές των παραμέτρων που κάνουν το μοντέλο να περιγράφει όσο το δυνατόν καλύτερα τα δεδομένα.
Μία **συνάρτηση απώλειας (loss / cost / objective function)** μετρά το σφάλμα, ενώ ένας **αλγόριθμος βελτιστοποίησης (optimizer / solver)** καθορίζει πώς μεταβάλλονται οι παράμετροι ώστε το σφάλμα να μειωθεί.

3 Αξιολόγηση (Evaluation)

Η απόδοση του μοντέλου εξετάζεται με κατάλληλες **μετρικές αξιολόγησης (evaluation metrics)**. Οι μετρικές που χρησιμοποιούνται εξαρτώνται από το είδος του προβλήματος, όπως **παλινδρόμηση, ταξινόμηση ή ομαδοποίηση**. Η αξιολόγηση πραγματοποιείται συνήθως κατά τον έλεγχο ή τη διασταυρωμένη επικύρωση του μοντέλου.

$$\underbrace{\mathbf{x} = [C, Cr, T, t]}_{\textbf{Αναπαράσταση}} \quad \textbf{Εκπαίδευση / Βελτιστοποίηση} \rightarrow \textbf{ελαχιστοποίηση σφάλματος} \quad \underbrace{\hat{HV} = f(\mathbf{x})}_{\textbf{Εκπαιδευμένο μοντέλο}} \quad \xrightarrow{\textbf{Αξιολόγηση}} \quad \hat{HV} \textbf{ έναντι } HV$$

Η Μηχανική Μάθηση δεν είναι μόνο η επιλογή ενός αλγορίθμου. Απαιτεί σωστή αναπαράσταση των δεδομένων, κατάλληλη βελτιστοποίηση του μοντέλου και αντικειμενική αξιολόγηση της απόδοσής του.

Βασική Πηγή: Liu, Z. (2025). *Artificial Intelligence for Engineers*.



Ενότητα 6

Εκπαίδευση, Αξιολόγηση και Ικανότητα Γενίκευσης

Διαχωρισμός δεδομένων

Στην επιβλεπόμενη Μηχανική Μάθηση, τα διαθέσιμα δεδομένα δεν χρησιμοποιούνται όλα με τον ίδιο τρόπο. Ένα μέρος χρησιμοποιείται για την **εκπαίδευση του μοντέλου**, ενώ ένα διαφορετικό μέρος διατηρείται για την **αξιολόγηση της απόδοσής του σε δεδομένα που δεν χρησιμοποιήθηκαν κατά την εκπαίδευση**.

Σύνολο Δεδομένων

$$D = \{x_i, y_i\}$$

Σύνολο Εκπαίδευσης (Training data)

- Χρησιμοποιούνται για την εκπαίδευση
- Προσδιορίζουν τις παραμέτρους
- Δίνουν στο μοντέλο την εμπειρία

Σύνολο Ελέγχου (Testing data)

- Δεν χρησιμοποιούνται στην εκπαίδευση
- Ελέγχουν την απόδοση
- Προσεγγίζουν νέα δεδομένα

Εκπαιδευμένο μοντέλο: $\hat{y} = f(x)$

Αξιολόγηση μοντέλου: $\hat{y}$ με y

Βασική Πηγή: Liu, Z. (2025). *Artificial Intelligence for Engineers*.

Σύνολο εκπαίδευσης (Training set)

Το **σύνολο εκπαίδευσης** είναι το τμήμα των διαθέσιμων δεδομένων που χρησιμοποιείται για την εκπαίδευση του μοντέλου. Στην επιβλεπόμενη μάθηση αποτελείται από γνωστά ζεύγη εισόδου – εξόδου. Οδηγεί στην εκτίμηση παραμέτρων.

Μαθηματική μορφή:

$$\mathcal{D}_{train} = \{(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_{n_{train}}, y_{n_{train}})\}$$

Κατά την εκπαίδευση:

$$\mathbf{x}_i \longrightarrow f(\mathbf{x}; \boldsymbol{\theta}) \longrightarrow \hat{y}_i$$

Και οι παράμετροι $\boldsymbol{\theta}$ προσαρμόζονται ώστε οι προβλέψεις $\hat{y}_i$ να προσεγγίζουν τις γνωστές τιμές y_i

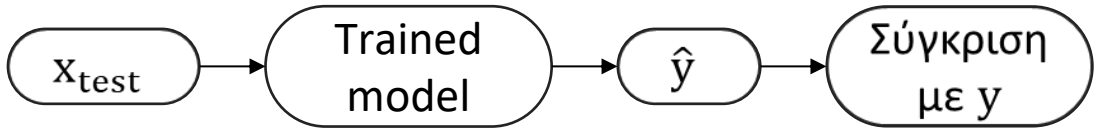
Η καλή απόδοση του μοντέλου όμως μόνο στα δεδομένα εκπαίδευσης **δεν αρκεί** για να γνωρίζουμε πώς θα συμπεριφερθεί σε νέα δεδομένα.
Χρειαζόμαστε ξεχωριστά δεδομένα αξιολόγησης για να εξετάσουμε αν το μοντέλο γενικεύει.

Βασική Πηγή: Liu, Z. (2025). *Artificial Intelligence for Engineers*.

Έλεγχος και διασταυρωμένη επικύρωση

Μετά ή κατά τη διάρκεια της εκπαίδευσης χρειαζόμαστε δεδομένα που μας επιτρέπουν να εκτιμήσουμε αν το μοντέλο λειτουργεί ικανοποιητικά πέρα από τα δείγματα που χρησιμοποιήθηκαν για την προσαρμογή των παραμέτρων του.

Έλεγχος (Testing)

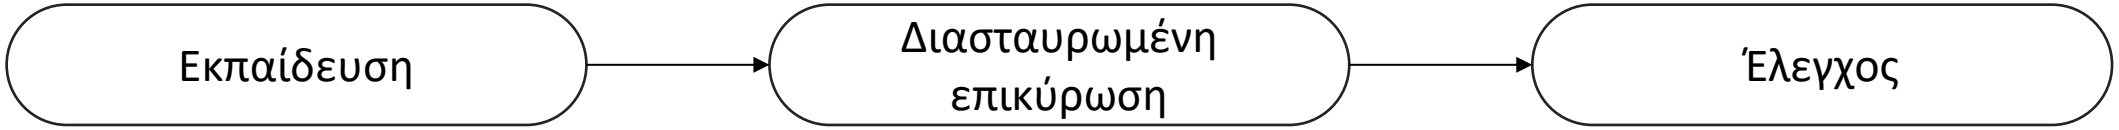


- Γίνεται μετά την εκπαίδευση
- Χρησιμοποιεί ανεξάρτητα δεδομένα
- Εκτιμά την τελική απόδοση
- Απαιτεί σύνολα ανεξάρτητα και όμοια κατανεμημένα (independent and identically distributed — IID)

Διασταυρωμένη επικύρωση (Cross-validation)



- τα δεδομένα χωρίζονται σε $kfolds$
- κάθε fold γίνεται μία φορά validation
- βοηθά στον έλεγχο του overfitting
- έχει μεγαλύτερο υπολογιστικό κόστος



Η διασταυρωμένη επικύρωση είναι μέρος της εκπαίδευσης, ενώ ο έλεγχος αφορά την τελική αξιολόγηση του μοντέλου.

Βασική Πηγή: Liu, Z. (2025). *Artificial Intelligence for Engineers*.

Ικανότητα γενίκευσης (Generalization)

Η **ικανότητα γενίκευσης (generalization)** περιγράφει το πόσο καλά ένα μοντέλο που εκπαιδεύτηκε χρησιμοποιώντας συγκεκριμένες παρατηρήσεις μπορεί να λειτουργήσει σε **νέα δεδομένα που δεν είχε δει κατά την εκπαίδευση**. Αυτό είναι και το νόημα που δίνει ο Liu στον όρο generalization: μετάβαση από συγκεκριμένες παρατηρήσεις σε γενικότερους κανόνες που μπορούν να εφαρμοστούν σε μελλοντικές περιπτώσεις.

Training data → Μάθηση → Μοντέλο → Νέα, άγνωστα δεδομένα

Καλή πρόβλεψη σε νέα δεδομένα ⇒ Καλή γενίκευση

Παράδειγμα στην Επιστήμη Υλικών

Ένα μοντέλο εκπαιδεύεται χρησιμοποιώντας γνωστά κράματα:

$$[C, Cr, T, t] \rightarrow HV$$

Ο πραγματικός στόχος δεν είναι απλώς να αναπαράγει τις σκληρότητες αυτών των κραμάτων, αλλά να προβλέπει με ικανοποιητική ακρίβεια τη σκληρότητα **νέων κραμάτων του ίδιου προβλήματος**.

Βασικό συμπέρασμα:

Στόχος της Μηχανικής Μάθησης δεν είναι η απομνημόνευση των δεδομένων εκπαίδευσης αλλά η μάθηση σχέσεων που μπορούν να γενικευθούν σε νέα δεδομένα.

Υποπροσαρμογή (Underfitting)

Η **υποπροσαρμογή (underfitting)** εμφανίζεται όταν το μοντέλο δεν μπορεί να περιγράψει ικανοποιητικά ούτε τις βασικές σχέσεις που υπάρχουν στα δεδομένα εκπαίδευσης. Χαρακτηρίζεται από **χαμηλή απόδοση τόσο στα δεδομένα εκπαίδευσης όσο και στα δεδομένα ελέγχου**.

Χαρακτηριστικά:

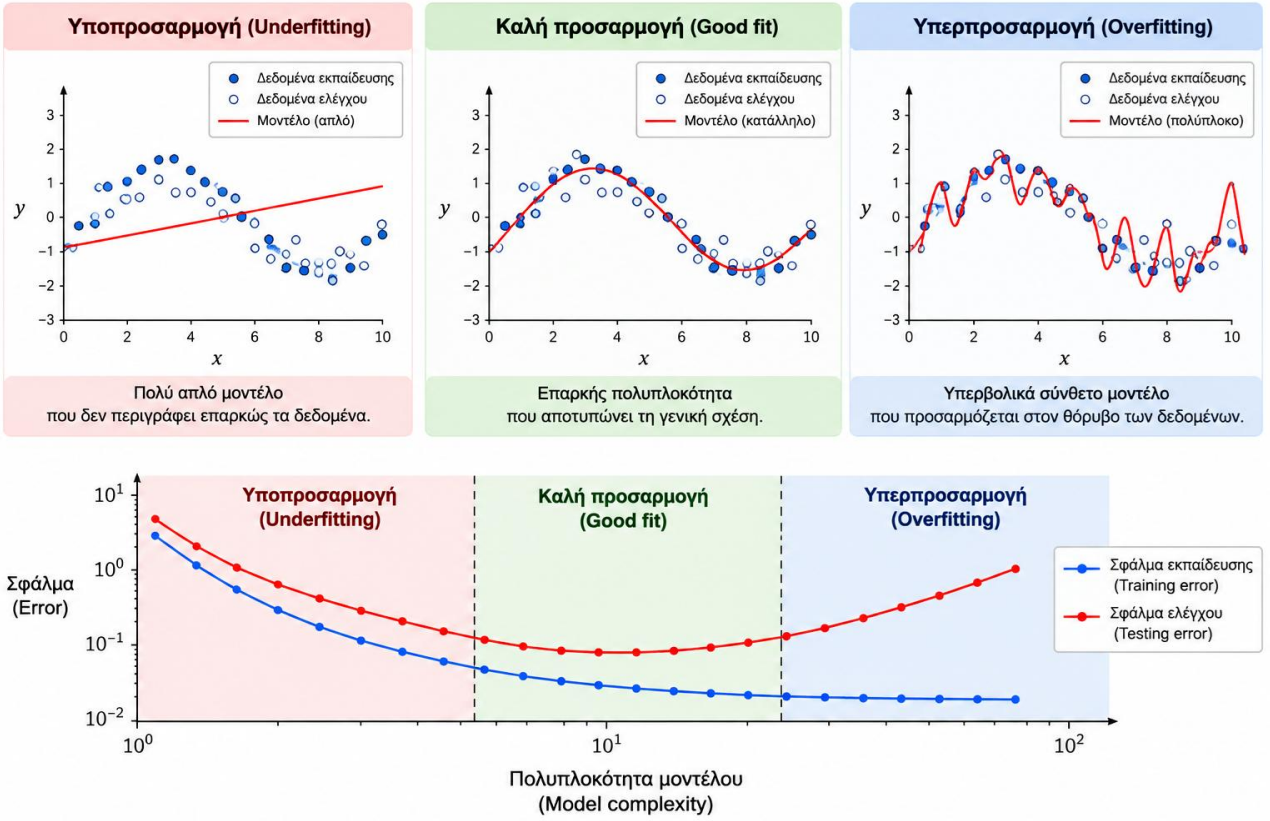
- Χαμηλή απόδοση στο σύνολο εκπαίδευσης
- Χαμηλή απόδοση στο σύνολο ελέγχου
- Το μοντέλο είναι πολύ απλό
- Δεν συλλαμβάνει τη βασική τάση

Αιτίες

- Ανεπαρκής πολυπλοκότητα
- Ελλιπής εκπαίδευση

Αντιμετώπιση

- Αύξηση πολυπλοκότητας, περισσότερες επαναλήψεις
- Πληρέστερη εκπαίδευση.



Βασική Πηγή: Liu, Z. (2025). *Artificial Intelligence for Engineers*.

Υπερπροσαρμογή (Overfitting)

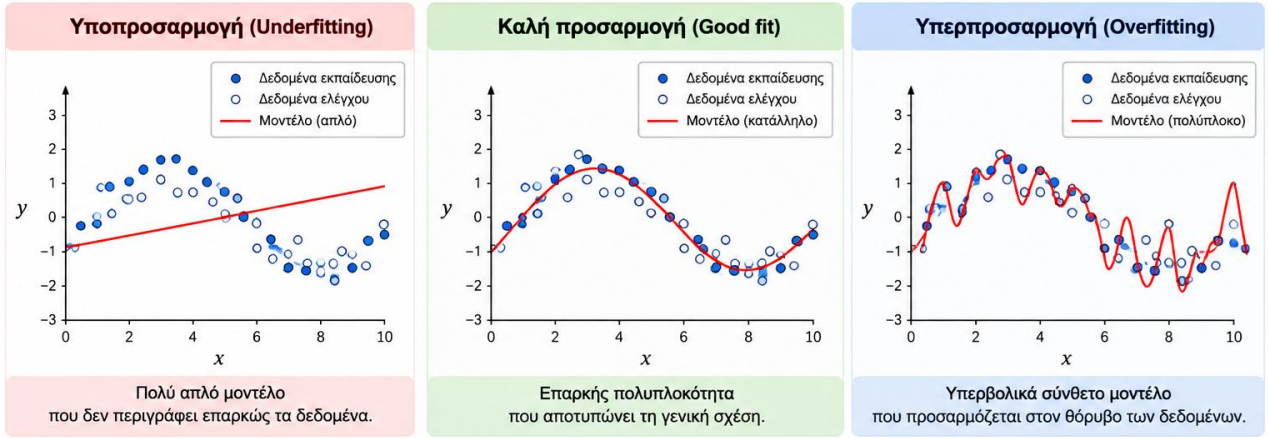
Η **υπερπροσαρμογή (overfitting)** εμφανίζεται όταν το μοντέλο προσαρμόζεται υπερβολικά στις ιδιαιτερότητες των δεδομένων εκπαίδευσης και η γνώση που αποκτά δεν μεταφέρεται ικανοποιητικά σε νέα δεδομένα.

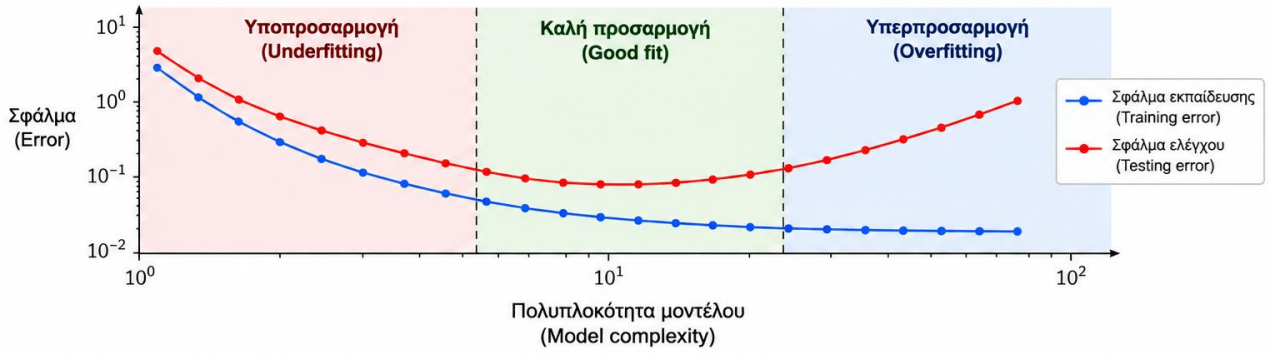
Χαρακτηριστικά

- Πολύ καλή απόδοση στο σύνολο εκπαίδευσης
- Σαφώς χειρότερη απόδοση στο σύνολο ελέγχου
- Το μοντέλο είναι υπερβολικά σύνθετο
- Ακολουθεί ακόμη και τον θόρυβο

Τρόποι περιορισμού:

- *Μοντέλο:*
  - κανονικοποίηση (regularization)
  - περικοπή μοντέλου (model trimming)
- *Εκπαίδευση:*
  - διαχωρισμός (holdout)
  - διασταυρωμένη επικύρωση (cross-validation)
  - πρόωρη διακοπή (early stopping)
- *Δεδομένα:*
  - περισσότερα δεδομένα
  - αύξηση δεδομένων (data augmentation)
  - επιλογή χαρακτηριστικών (feature selection)



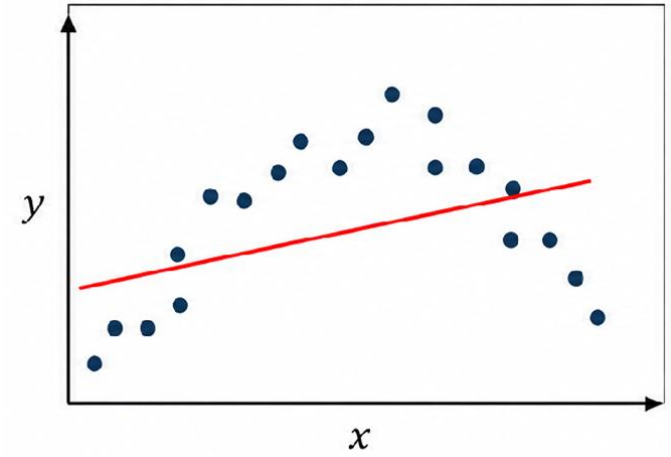


Βασική Πηγή: Liu, Z. (2025). *Artificial Intelligence for Engineers*.

Πολυπλοκότητα και γενίκευση

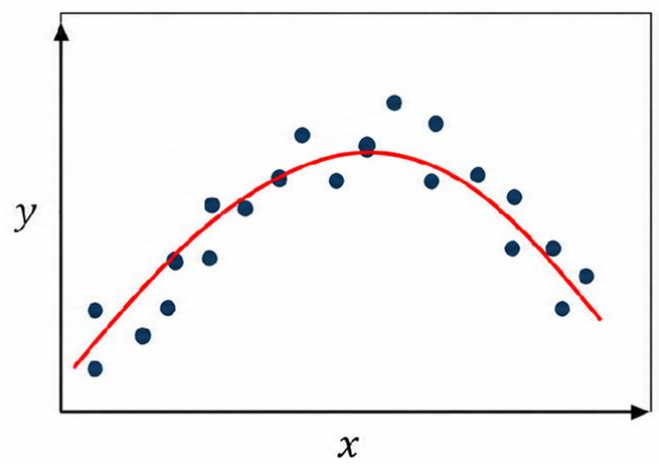
Η πολυπλοκότητα του μοντέλου επηρεάζει την ικανότητά του να περιγράψει τα δεδομένα, αλλά περισσότερη πολυπλοκότητα δεν σημαίνει απαραίτητα καλύτερη γενίκευση.

Χαμηλή πολυπλοκότητα
Underfitting



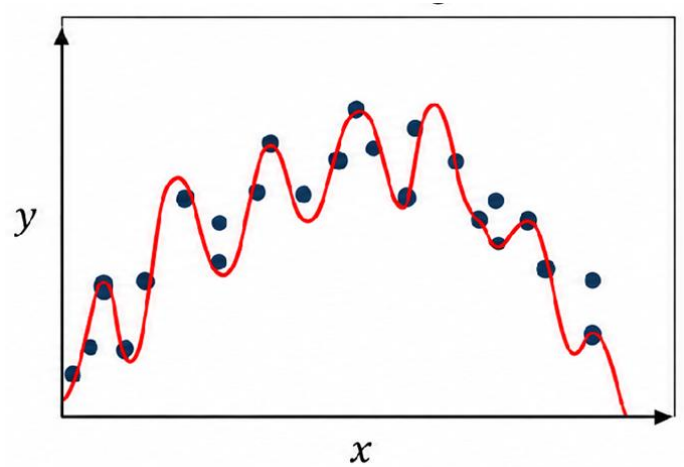
- Ανεπαρκής προσαρμογή
- Χαμηλή απόδοση

Κατάλληλη πολυπλοκότητα
Good fit



- Αποτυπώνει τη γενική σχέση
- Καλή γενίκευση

Υψηλή πολυπλοκότητα
Overfitting



- Προσαρμογή στον θόρυβο
- Μειωμένη γενίκευση

Στόχος δεν είναι το μοντέλο να προσαρμόζεται καλύτερα στα δεδομένα εκπαίδευσης, αλλά να αποδίδει αξιόπιστα σε νέα δεδομένα.

Βασική Πηγή: Liu, Z. (2025). *Artificial Intelligence for Engineers*.



Ενότητα 7

Αλγόριθμοι, Ροή Εργασίας και Περιορισμοί της Μηχανικής Μάθησης

Βασικές οικογένειες αλγορίθμων

Οι κατηγορίες μάθησης (που είδαμε στην Ενότητα 4) μας λένε τι είδους πρόβλημα έχουμε.

- Για κάθε κατηγορία υπάρχουν πολλοί αλγόριθμοι· η επιλογή εξαρτάται από τη μορφή των δεδομένων και την εργασία.

Επιβλεπόμενη μάθηση: οι πιο συνηθισμένοι αλγόριθμοι

Γραμμικά μοντέλα

Γραμμική συνάρτηση των εισόδων· Ridge, Lasso κατά της υπερπροσαρμογής

Δέντρα απόφασης

Διαδοχικοί κανόνες σε μορφή δέντρου (ID3, C4.5, CART)

SVM

Διαχωρισμός κλάσεων με το μέγιστο περιθώριο· kernels για μη γραμμικά

Μέθοδοι Bayes

Πιθανοτική ταξινόμηση (Naive Bayes, δίκτυα Bayes)

Νευρωνικά δίκτυα & BM

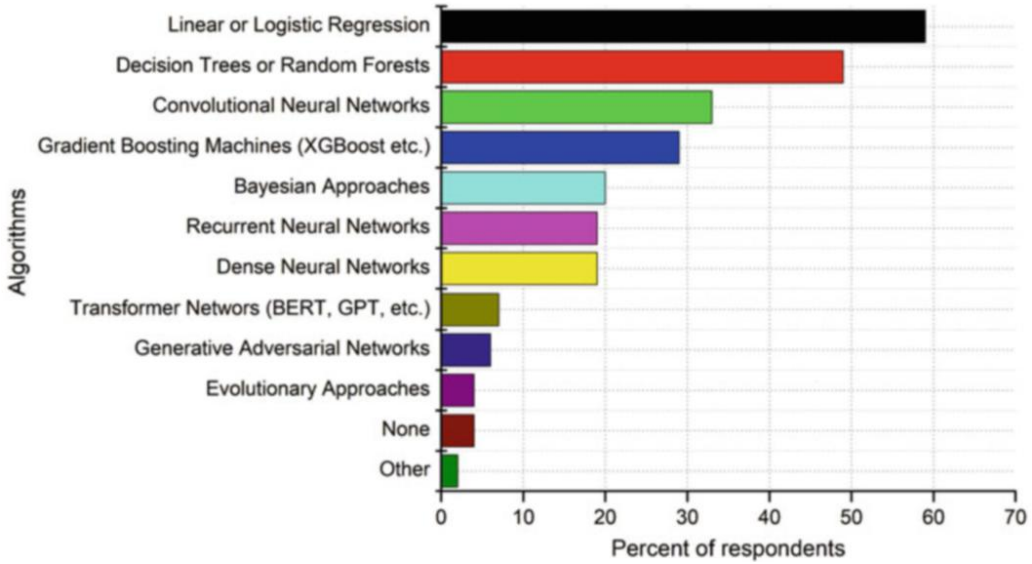
Επίπεδα τεχνητών νευρώνων· εκπαίδευση με backpropagation

Ensemble

Συνδυασμός πολλών μοντέλων: Random Forest, Boosting, Stacking

Μη επιβλεπόμενη: K-Means, DBSCAN, PCA, autoencoders

Ενισχυτική: Q-learning, Sarsa, policy gradient, actor-critic



Οι πιο διαδεδομένοι αλγόριθμοι ΜΜ, έρευνα Kaggle 2020 (18.996 συμμετέχοντες).

Βασική Πηγή: Liu, Z. (2025). *Artificial Intelligence for Engineers*.

Από πρόβλημα Υλικών σε Μηχανικής Μάθησης

Πριν επιλέξουμε αλγόριθμο, πρέπει να μετατρέψουμε το επιστημονικό ή μηχανικό ερώτημα σε σαφώς ορισμένο πρόβλημα Μηχανικής Μάθησης

Ερώτημα	**Στόχος**	**Χαρακτηριστικά**	**Εργασία ML**	**Δεδομένα**	**Αλγόριθμος**
Τι θέλουμε να μάθουμε;	Ποια είναι η έξοδος;	Ποιες είναι οι είσοδοι;	Regression / Classification / Clustering	Σύνολο δεδομένων με δείγματα	Πώς θα μάθει το μοντέλο;

Παράδειγμα: Πρόβλεψη σκληρότητας κράματος

Μπορούμε να προβλέψουμε τη σκληρότητα; → $y = HV$ → $\mathbf{x} = [C, Cr, T, t]$ → Regression → $\{x_i, HV_i\}$ → Π.χ. Γραμμική Παλινδρόμηση

Άλλα Παραδείγματα

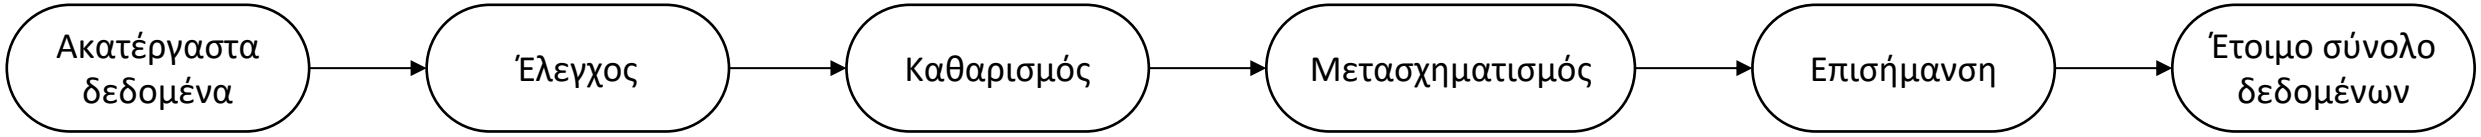
Κατηγορία Μικροδομής → Εικόνες / Χαρακτηριστικά μικροδομής → Ταξινόμηση

Άγνωστες Μικροδομές → Χαρακτηριστικά μικροδομής → Ομαδοποίηση

Βασική Πηγή: Liu, Z. (2025). *Artificial Intelligence for Engineers*.

Προετοιμασία και ποιότητα δεδομένων

Στις εφαρμογές Μηχανικής, η προετοιμασία των δεδομένων συχνά απαιτεί σημαντική προσπάθεια και επηρεάζει άμεσα την ποιότητα του τελικού μοντέλου



Ανεπαρκή Δεδομένα

- Λίγα ή μη επαρκή δείγματα
- Δυσκολία κάλυψης του προβλήματος

Μη ώριμα δεδομένα

- Ελλιπή ή ετερογενή
- Απαιτούν προεπεξεργασία

Λανθασμένα Δεδομένα

- Δεδομένα χωρίς ετικέτες
- Συστηματικά σφάλματα

Θορυβώδη Δεδομένα

- Τυχαίες αποκλίσεις
- Ανάγκη για φιλτράρισμα

Μεροληπτικά Δεδομένα

- Μη αντιπροσωπευτικό σύνολο δεδομένων
- κίνδυνος μεροληπτικών προβλέψεων (skewed predictions)

Η ποιότητα του μοντέλου δεν μπορεί να υπερβεί την ποιότητα και την αντιπροσωπευτικότητα των δεδομένων του.

Βασική Πηγή: Liu, Z. (2025). *Artificial Intelligence for Engineers*.

Προκλήσεις της Μηχανικής Μάθησης

Ένα επιτυχημένο έργο Μηχανικής Μάθησης δεν εξαρτάται μόνο από τον αλγόριθμο, αλλά από την συνδυασμένη ποιότητα των δεδομένων, του μοντέλου, της εκπαίδευσης και της αξιολόγησης

Δεδομένα	Αναπαράσταση / μοντέλο	Επαγωγική προκατάληψη	Γενίκευση / αξιολόγηση
• ανεπαρκή, θορυβώδη ή λανθασμένα • πιθανή μεροληψία • κρίσιμη η αντιπροσωπευτικότητα	• ακατάλληλα χαρακτηριστικά • λανθασμένη πολυπλοκότητα • μοντέλο μη κατάλληλο για το πρόβλημα	• κάθε αλγόριθμος ενσωματώνει υποθέσεις • οι υποθέσεις καθοδηγούν τη λύση • βοηθούν αλλά και περιορίζουν	• καλή επίδοση στην εκπαίδευση δεν αρκεί • απαραίτητος ανεξάρτητος έλεγχος • αξιόπιστη πρόβλεψη σε νέα δεδομένα

Δεδομένα + Αναπαράσταση + Αλγόριθμος + Εκπαίδευση → Μοντέλο

↓

Αξιολόγηση σε νέα δεδομένα → Αξιόπιστη Εφαρμογή

Ένα καλό μοντέλο προκύπτει από σωστή διατύπωση του προβλήματος, κατάλληλα δεδομένα, ορθή εκπαίδευση και αξιόπιστη αξιολόγηση.

Βασική Πηγή: Liu, Z. (2025). *Artificial Intelligence for Engineers*.



Ενότητα 8

Εφαρμογές στην Επιστήμη και Μηχανική Υλικών

Εφαρμογές ΤΝ στη Μηχανική

Η Τεχνητή Νοημοσύνη μπορεί να υποστηρίξει διαφορετικά στάδια της μηχανικής πρακτικής, από την επεξεργασία δεδομένων και την πρόβλεψη έως τον σχεδιασμό, τη βελτιστοποίηση και την αυτοματοποίηση.

1. Επεξεργασία Δεδομένων
Ανάλυση μετρήσεων, εικόνων, σημάτων, προσομοιώσεων και άλλων μηχανικών δεδομένων

2. Παρακολούθηση Συστημάτων
Ανίχνευση ανωμαλιών, βλαβών και μεταβολών στη λειτουργία

3. Πρόβλεψη
Εκτίμηση μελλοντικής συμπεριφοράς, διάρκειας ζωής ή άλλων μεγεθών

4. Σχεδιασμός
Υποστήριξη επιλογών σχεδιασμού και σύγκριση εναλλακτικών λύσεων

5. Διαχείριση
Υποστήριξη αποφάσεων σε πόρους, εξοπλισμό, δεδομένα και διαδικασίες.

6. Βελτιστοποίηση
Αναζήτηση συνθηκών ή λύσεων που ικανοποιούν καλύτερα έναν στόχο

7. Αυτοματοποίηση
Χρήση τεχνητής νοημοσύνης για έλεγχο, λήψη αποφάσεων και αυτόνομη λειτουργία

Η τεχνητή νοημοσύνη δεν αντικαθιστά μία μόνο διαδικασία της Μηχανικής. Μπορεί να λειτουργήσει σε ολόκληρη την αλυσίδα:

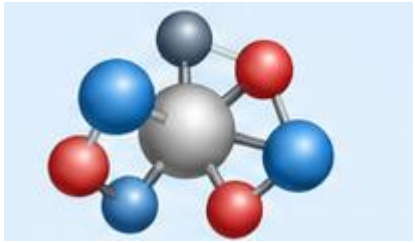
Δεδομένα → **Ανάλυση** → **Απόφαση** → **Δράση**

Βασική Πηγή: Liu, Z. (2025). *Artificial Intelligence for Engineers*.

ΤΝ στην Επιστήμη Υλικών

Στην επιστήμη Υλικών, η Μηχανική Μάθηση μπορεί να συνδέσει σύσταση, επεξεργασία και μικροδομή με τις ιδιότητες και την απόδοση ενός υλικού.

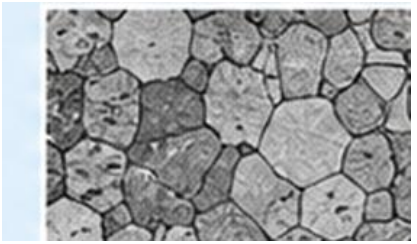
Σύσταση



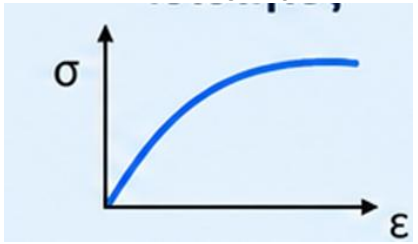
Επεξεργασία



Μικροδομή



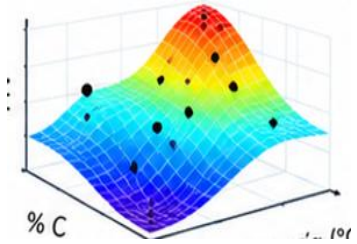
Ιδιότητες



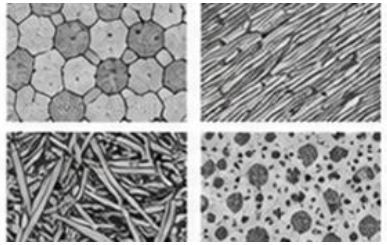
Απόδοση



Πρόβλεψη ιδιοτήτων



Ταξινόμηση μικροδομών



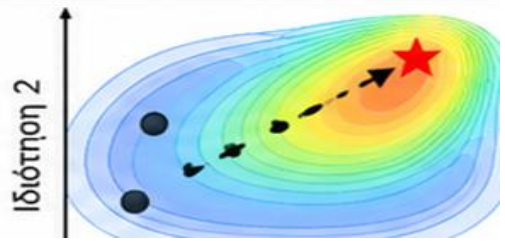
Ομαδοποίηση δεδομένων



Ανίχνευση ανωμαλιών



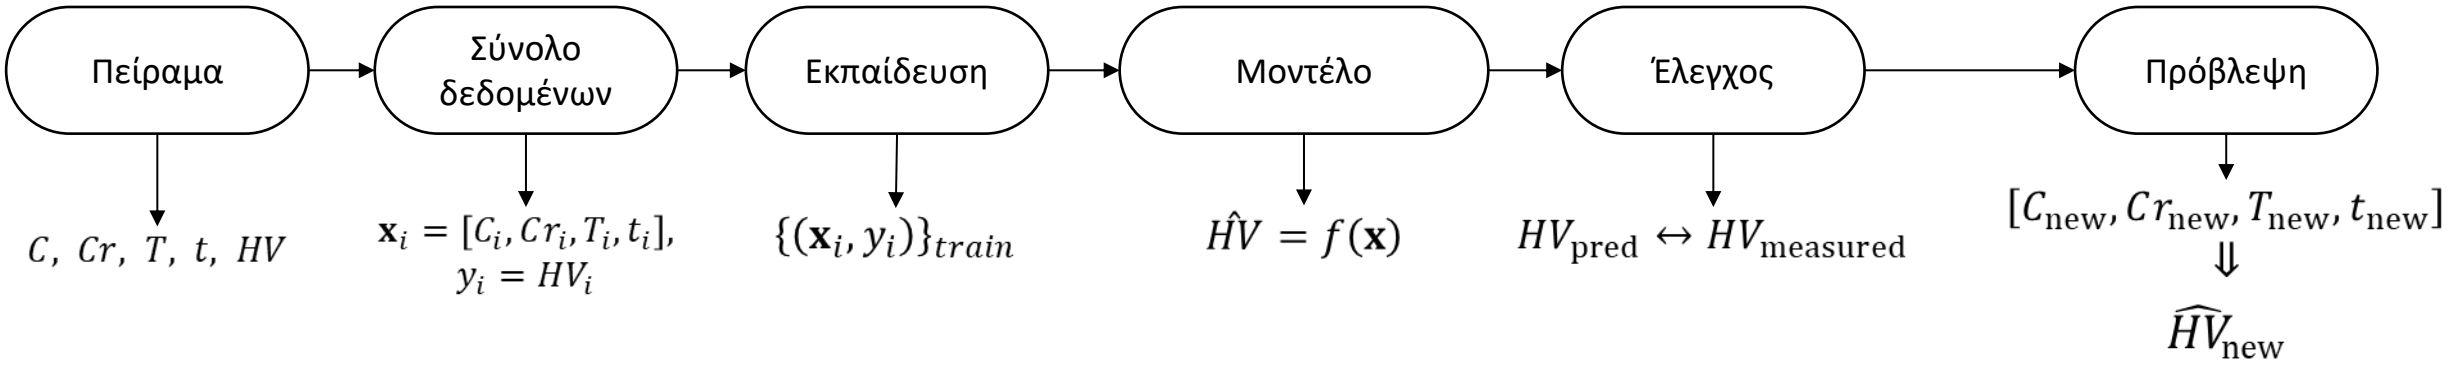
Σχεδιασμός/βελτιστοποίηση υλικών



Βασική Πηγή: Liu, Z. (2025). *Artificial Intelligence for Engineers*.

Από τα δεδομένα στην πρόβλεψη ιδιότητας

Είναι εφικτό να προβλεφθεί η σκληρότητα ενός νέου κράματος από τη χημική σύσταση και τις συνθήκες κατεργασίας



Η πραγματική αξία του μοντέλου εμφανίζεται όταν μπορεί να προβλέψει αξιόπιστα την ιδιότητα ενός νέου υλικού και όχι όταν απλώς αναπαράγει τα δεδομένα εκπαίδευσης.

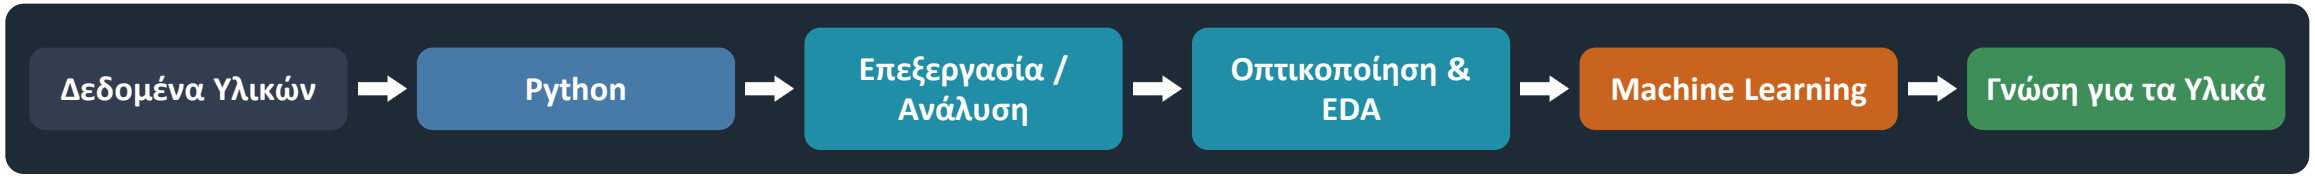
Βασική Πηγή: Liu, Z. (2025). *Artificial Intelligence for Engineers*.

Στο Επόμενο Μάθημα

ΜΑΘΗΜΑ 2

Εισαγωγή στην Python για Τεχνητή Νοημοσύνη και Επιστήμη Υλικών

Workshop / Διάλεξη με Live Coding



Στο workshop θα:

- Γράψετε βασικό κώδικα Python
- Δουλέψετε με δεδομένα υλικών
- Χρησιμοποιήσετε NumPy / Pandas
- Δημιουργήσετε γραφήματα και EDA
- Εκπαιδεύσετε ένα πρώτο μοντέλο Machine Learning

Μπορείτε να φέρετε τον φορητό υπολογιστή σας ώστε να ακολουθήσετε το Live Coding.

Βασική Πηγή: Liu, Z. (2025). *Artificial Intelligence for Engineers*.