




Applied Δ i in Healthcare

Understanding AI systems in clinical and real-world contexts





Let's Think



*"În 2012, un AI a recunoscut o pisică.
Fără să știe ce este o pisică.
Azi, AI-ul poate ajuta la diagnosticarea cancerului.
Ce s-a întâmplat între timp?"*



Ce se întâmplă ACUM în AI medical?

Noutate 2025–2026	De ce e relevant pentru tine
Studiul MASAI (The Lancet, 2025): AI detectat cu acuratete superioara radiologilor in screening mamografic – cu 25% mai multe cancere interval depistate decat metodele standard	Tu vei fi inginerul care validează sau construiește astfel de sisteme
Modelul CHIEF (Harvard Medical School): ~94% acuratete in detectia cancerului pe 15 tipuri, pe 11.000+ cazuri. Depaseste alte modele AI cu pana la 36%	Performanta nu inseamna nimic fara validare clinica – tu trebuie sa stii ce intrebari sa pui
Piata globala AI in sanatate: 26,6 miliarde USD in 2024, estimat 187 miliarde USD in 2030 (CAGR ~38,5%). Romania isi aliniaza ecosistemul la EU AI Act (2024/1689)	Exista locuri de munca, startup-uri si proiecte de cercetare care asteapta ingineri cu aceasta competenta
Prof. Valmed – primul asistent AI certificat in Europa sa ajute medicii la diagnostic si tratament (2025)	Reglementarea europeana prinde contur: AI Act + MDR definesc cadrul in care vei lucra
86% din organizatiile medicale din lume folosesc deja AI in fluxuri de lucru reale (StartUs Insights, 2025)	Nu este o tehnologie a viitorului – este o realitate curenta la care trebuie sa te pregatesti



Analogii: AI prin experiența umană

AI invata din exemple

"AI can be compared to a child learning from experience.
It does not follow fixed rules.
It learns patterns from data."

Machine Learning <i>Ca un copil care învață să recunoască animale – nu după un manual, ci din mii de exemple. Vede câini, pisici, cai și construiește treptat un model intern al fiecăruia.</i>	Dataset <i>Ca experiența de viață. Cu cât experiențele sunt mai bogate, mai diverse și mai corecte, cu atât judecata devine mai bună. Un copil crescut în izolare va avea puncte oarbe – la fel și un AI antrenat pe date limitate.</i>
Bias <i>Ca o educație greșită. Dacă un copil este învățat că un anumit grup de oameni se comportă întotdeauna într-un anumit fel, dezvoltă prejudecăți. AI antrenat pe date distorsionate dezvoltă același tip de eroare sistematică.</i>	Overfitting <i>Ca un elev care memorează doar exercițiile din culegere. Ia notă maximă la simulare, dar pică la examenul real. Modelul a memorat, nu a învățat.</i>
Neural Network <i>Ca o echipă de oameni care votează o decizie. Fiecare persoană (neuron) are o perspectivă parțială. Decizia finală rezultă din votul colectiv, ponderat în funcție de istoricul fiecăruia.</i>	Deep Learning <i>Ca o echipă organizată pe straturi. Rândul din față detectează trăsături simple (contururi, texturi). Transmite mai departe, iar rândul următor detectează tipare. La final, echipa recunoaște fețe, voci, tumori.</i>



Activitate: Joacă rolul unui model AI



Obiectiv: Experimentați direct cum ia AI decizii – și simțiți limitele sale.

Instrucțiuni:

1. Fiecare student primește un card cu un set limitat de date (ex: vârstă, rezultat analiză, simptome).
2. Studentul trebuie să ia o decizie bazat EXCLUSIV pe datele de pe card – fără asumții, fără intuiție.
3. Se dezvăluie «rezultatul real» – a fost suficientă informația pentru o decizie corectă?

Debrief questions:

Ce lipsea de pe cardul tău?

La ce asumții ai fost tentat(ă) să recurgi?

Cum schimbă asta perspectiva ta asupra diagnosticului asistat de AI?



Cazul de deschidere: Spitalul X



Case Scenario

Spitalul X implementează un sistem AI pentru suport decizional clinic.

Medicii vor vedea recomandările generate de AI alături de dosarul pacientului.

Sistemul a fost antrenat pe 500.000 de cazuri din trei spitale mari.

A fost validat pe date interne cu 87% acuratețe pentru condiția țintă.

Ce ar trebui să știm despre acest AI?




Ethical Teaser: The Moral Machine Experiment

Background

În 2014, cercetătorii de la MIT Media Lab au conceput experimentul *Moral Machine* — o platformă gamificată care a colectat deciziile publicului despre cum ar trebui mașinile autonome să prioritizeze vieți în variante ale dilemei «tramvaiului».

Datele au revelat ceva surprinzător: prioritățile etice diferă semnificativ între culturi, grupe de vârstă și profesii.


Aceeași situație. Decizii foarte diferite.



Discussion Prompt

«Dacă un sistem AI este antrenat pe deciziile luate de o anumită cultură sau un anumit spital, ar trebui implementat într-un alt context fără adaptare?»

Țineți această întrebare în minte. Ne vom întoarce la ea în Modulul 3 (Etică și Bias).



Modulul 1: Concepte Fundamentale AI în Sănătate

Obiective de învățare


1. Definirea AI, ML, Deep Learning și Generative AI – și distingerea dintre ele
2. Înțelegerea modului în care sistemele AI învață din date
3. Identificarea tipurilor de date utilizate în AI medical
4. Recunoașterea rolului profesionistului medical în fluxurile asistate de AI
5. Evaluarea critică a aplicațiilor AI reale din domeniul sănătății



Modulul 1: Concepte Fundamentale AI în Sănătate

1.1 Definirea Inteligenței Artificiale

Inteligența Artificială nu este un singur lucru — ci o familie de abordări care permit calculatoarelor să realizeze sarcini ce necesită în mod normal inteligență umană: recunoașterea tiparelor, realizarea de predicții, generarea de limbaj și sprijinirea deciziilor.



INTELIGENȚĂ ARTIFICIALĂ — sisteme care simulează inteligența umană

MACHINE LEARNING — un subset al AI — învățat din date

DEEP LEARNING — un subset al ML — rețele neuronale multi-strat

GENERATIVE AI — un subset al DL — creează conținut nou

Concept	Definiție într-un rând
Inteligență Artificială	Mașini care simulează inteligența umană pentru a rezolva sarcini
Machine Learning	AI care învață tipare din date — fără a fi programat explicit
Deep Learning	ML ce folosește rețele neuronale multi-strat pentru date complexe (imagini, text, semnale)
Generative AI	Modele Deep Learning care generează conținut nou: text, imagini, date sintetice



Modulul 1: Concepte Fundamentale AI în Sănătate


1.2 Cum Învăță Sistemele AI

AI nu urmează reguli pre-scrise. Învăță din exemple. Înțelegerea acestui proces este esențială pentru a înțelege atât puterea, cât și limitele sale.

Procesul de învățare

(Supervised Learning = cel mai frecvent în sănătate)

Pas	Ce se întâmplă	Exemplu medical
1	Colectare date etichetate	10.000 radiografii toracice, fiecare etichetată: «pneumonie»
2	Antrenarea modelului	Algoritmul ajustează parametrii interni pentru a minimiza erorile de
3	Validarea performanței	Test pe radiografii nevăzute – se măsoară acuratețe, sensibilitate,
4	Implementare și monitorizare	Sistemul asistă radiologii – performanța este urmărită în timp



Concepte cheie

- **Training data** — the examples the model learns from. Garbage in, garbage out.
- **Labels** — the correct answers in supervised learning (e.g., "malignant" / "benign")
- **Model** — the mathematical function that maps inputs to outputs after training
- **Overfitting** — when the model memorizes training data and fails on new cases
- **Underfitting** — when the model is too simple to capture important patterns
- **Validation set** — data held back from training, used to tune the model
- **Test set** — data held back entirely, used only once to report final performance



Modulul 1: Concepte Fundamentale AI în Sănătate

1.3 Tipuri de Date în AI Medical

Tip de date	Exemple	Provocare pentru AI
Clinic / structurat	Valori de laborator, semne vitale, medicamente, diagnostice (coduri ICD)	Valori lipsă, codificare inconsistentă între spitale
Imagistică medicală	Radiografie, CT, RMN, ecografie, lame de histopatologie	Fișiere mari, necesită adnotare de experți
Text liber (EHR)	Note clinice, scrisori de externare, rapoarte de radiologie	Abrevieri, greșeli de scriere, ambiguitate, variabilitate lingvistică
Genomic / molecular	Secvențe ADN, paneluri de biomarkeri, date omics	Dimensionalitate înaltă, boli rare, interpretabilitate redusă
Wearable / senzori	ECG, SpO2, glucoză continuă, date de activitate	Zgomot de semnal, variabilitate între dispozitive, date lipsă

De ce contează calitatea datelor în sănătate

Un sistem AI este la fel de bun ca datele pe care a fost antrenat.

În sănătate, calitatea slabă a datelor nu este doar o problemă tehnică – este o problemă de siguranță a pacientului.

Probleme frecvente de calitate a datelor:

- Înregistrări incomplete (diagnostice lipsă, valori de laborator abandonate)
- Bias de populație (antrenat predominant pe un grup demografic)
- Deriva temporală (populațiile de pacienți se schimbă în timp)
- Zgomot în etichete (experții nu sunt de acord în 10–20% din cazuri)

De aceea, curatarea datelor, guvernarea și documentația sunt la fel de importante ca algoritmul.



Modulul 1: Concepte Fundamentale AI în Sănătate

1.4 Cum Funcționează Sistemele AI în Sănătate – Nivel Conceptual

#	Etapă	Descriere și întrebări cheie
1	Definirea problemei	Ce problemă clinică rezolvăm? Pentru cine? Cum arată succesul?
2	Colectarea datelor	De unde provin datele? Sunt reprezentative? Au fost consimțite?
3	Preprocesarea datelor	Cum sunt tratate valorile lipsă? Cum sunt normalizate imaginile? Ce biasuri pot fi introduse?
4	Antrenarea modelului	Ce algoritm se folosește? Care sunt seturile de antrenament și validare?
5	Evaluarea modelului	Ce metrici s-au folosit? Acuratețe? Sensibilitate? AUC? Pe ce populație?
6	Implementare	Cum este AI integrat în fluxul clinic? Cine vede outputul?
7	Monitorizare	Performanța este urmărită în timp? Ce se întâmplă când modelul degradează?



Modulul 1: Concepte Fundamentale AI în Sănătate

1.5 Particularitățile Sănătății ca Domeniu AI

Ce face AI medical mai dificil	De ce contează
Mize ridicate: erorile pot răni sau ucide pacienți	Cerințele de robustețe și siguranță sunt mai ridicate decât în majoritatea domeniilor
Cadru de reglementare: Marcaj CE, FDA 510(k), MDR	AI ca dispozitiv medical necesită validare clinică și aprobare regulatorie
Scarcitate de date: boli rare, seturi de date mici și adnotate	Modelele pot suprainvăța sau eșua la generalizare în alte spitale
Distribution shift: fiecare spital are propriile tipare	Un model antrenat într-un spital poate performa slab în altul
Cerinte de interpretabilitate: clinicienii trebuie să aibă încredere	Modelele black-box sunt adesea insuficiente; explicabilitatea contează
Complexitate multimodală: imagini + date clinice + text	Integrarea este dificilă atât tehnic, cât și organizațional



Modulul 1: Concepte Fundamentale AI în Sănătate

1.6 Evaluarea Performanței AI

Metrică	Ce măsoară	Exemplu medical
Acuratețe	% din toate predicțiile care sunt corecte	95% din radiografiile clasificate corect
Sensibilitate (Recall)	% din cazurile pozitive reale detectate corect	Câte cancere reale a prins AI?
Specificitate	% din cazurile negative reale excluse corect	De câte ori a spus corect «nu cancer»?
AUC-ROC	Capacitatea globală de discriminare a modelului	Mai aproape de 1,0 = separare mai bună a claselor
F1 Score	Media armonică a preciziei și recall-ului	Util când clasele sunt dezechilibrate

Capcana celor 95% acuratețe

Imaginați-vă un set de date în care **95%** din pacienți NU au o anumită condiție.

Un AI care prezice întotdeauna «fără condiție» obține 95% acuratețe.

Dar nu prinde NICIUN caz real.

De aceea acuratețea singură nu este suficientă în sănătate.

Întotdeauna întrebați: **Care este sensibilitatea? Care este rata fals negativă?**

Ce se întâmplă cu pacienții pe care AI îi ratează?



Modulul 1: Concepte Fundamentale AI în Sănătate

1.7 Rolul Profesionistului Medical în Sistemele AI

Automatizare	Asistare
AI decide și acționează fără intervenție umană	AI recomandă – omul decide și acționează
Exemplu: alertă automată de tensiune arterială	Exemplu: AI marchează o leziune suspectă pe CT – radiologul confirmă
Eficiență ridicată, flexibilitate redusă	Păstrează judecata clinică, adaugă suport cognitiv
Potrivit pentru sarcini cu risc scăzut, bine definite	Necesar pentru decizii diagnostice și terapeutice

Distincția cheie pentru inginerii biomedicali:

- Automatizarea înlocuiește o acțiune umană într-o sarcină definită, cu risc redus.
- Asistarea sprijină decizia umană în situații complexe, cu mize ridicate.
- Decizia complet autonomă a AI (fără supraveghere umană) este rar adecvată în clinică și adesea ilegală conform regulamentelor UE.



Modulul 1: Concepte Fundamentale AI în Sănătate

1.8 Aplicații Reale AI în Sănătate



Domeniu	Ce face AI	Exemplu real	Tip AI
Radiologie	Detectează anomalii pe Rx, CT, RMN	XVision / Rayscape – utilizat de Regina Maria, România	Deep Learning
Anatomopatologie	Analizează lame tisulare pentru markeri de cancer	Paige AI – aprobat FDA pentru cancerul de prostată	Deep Learning
Rezumare EHR	Extrage informații cheie din note clinice	Nabla, Suki – asistenți AI pentru documentație medicală	GenAI / NLP
Predicție sepsis	Prezice riscul de sepsis din semne vitale și analize	Epic Sepsis Model – larg implementat în SUA	Machine Learning
Screening mamografic	Detectează cancere suplimentare fata de radiologi	Studiul MASAI (Lancet 2025): +25% cancere interval detectate	Deep Learning

Modulul 1: Concepte Fundamentale AI în Sănătate

Mini studiu de caz: Evaluarea unui sistem AI în sănătate

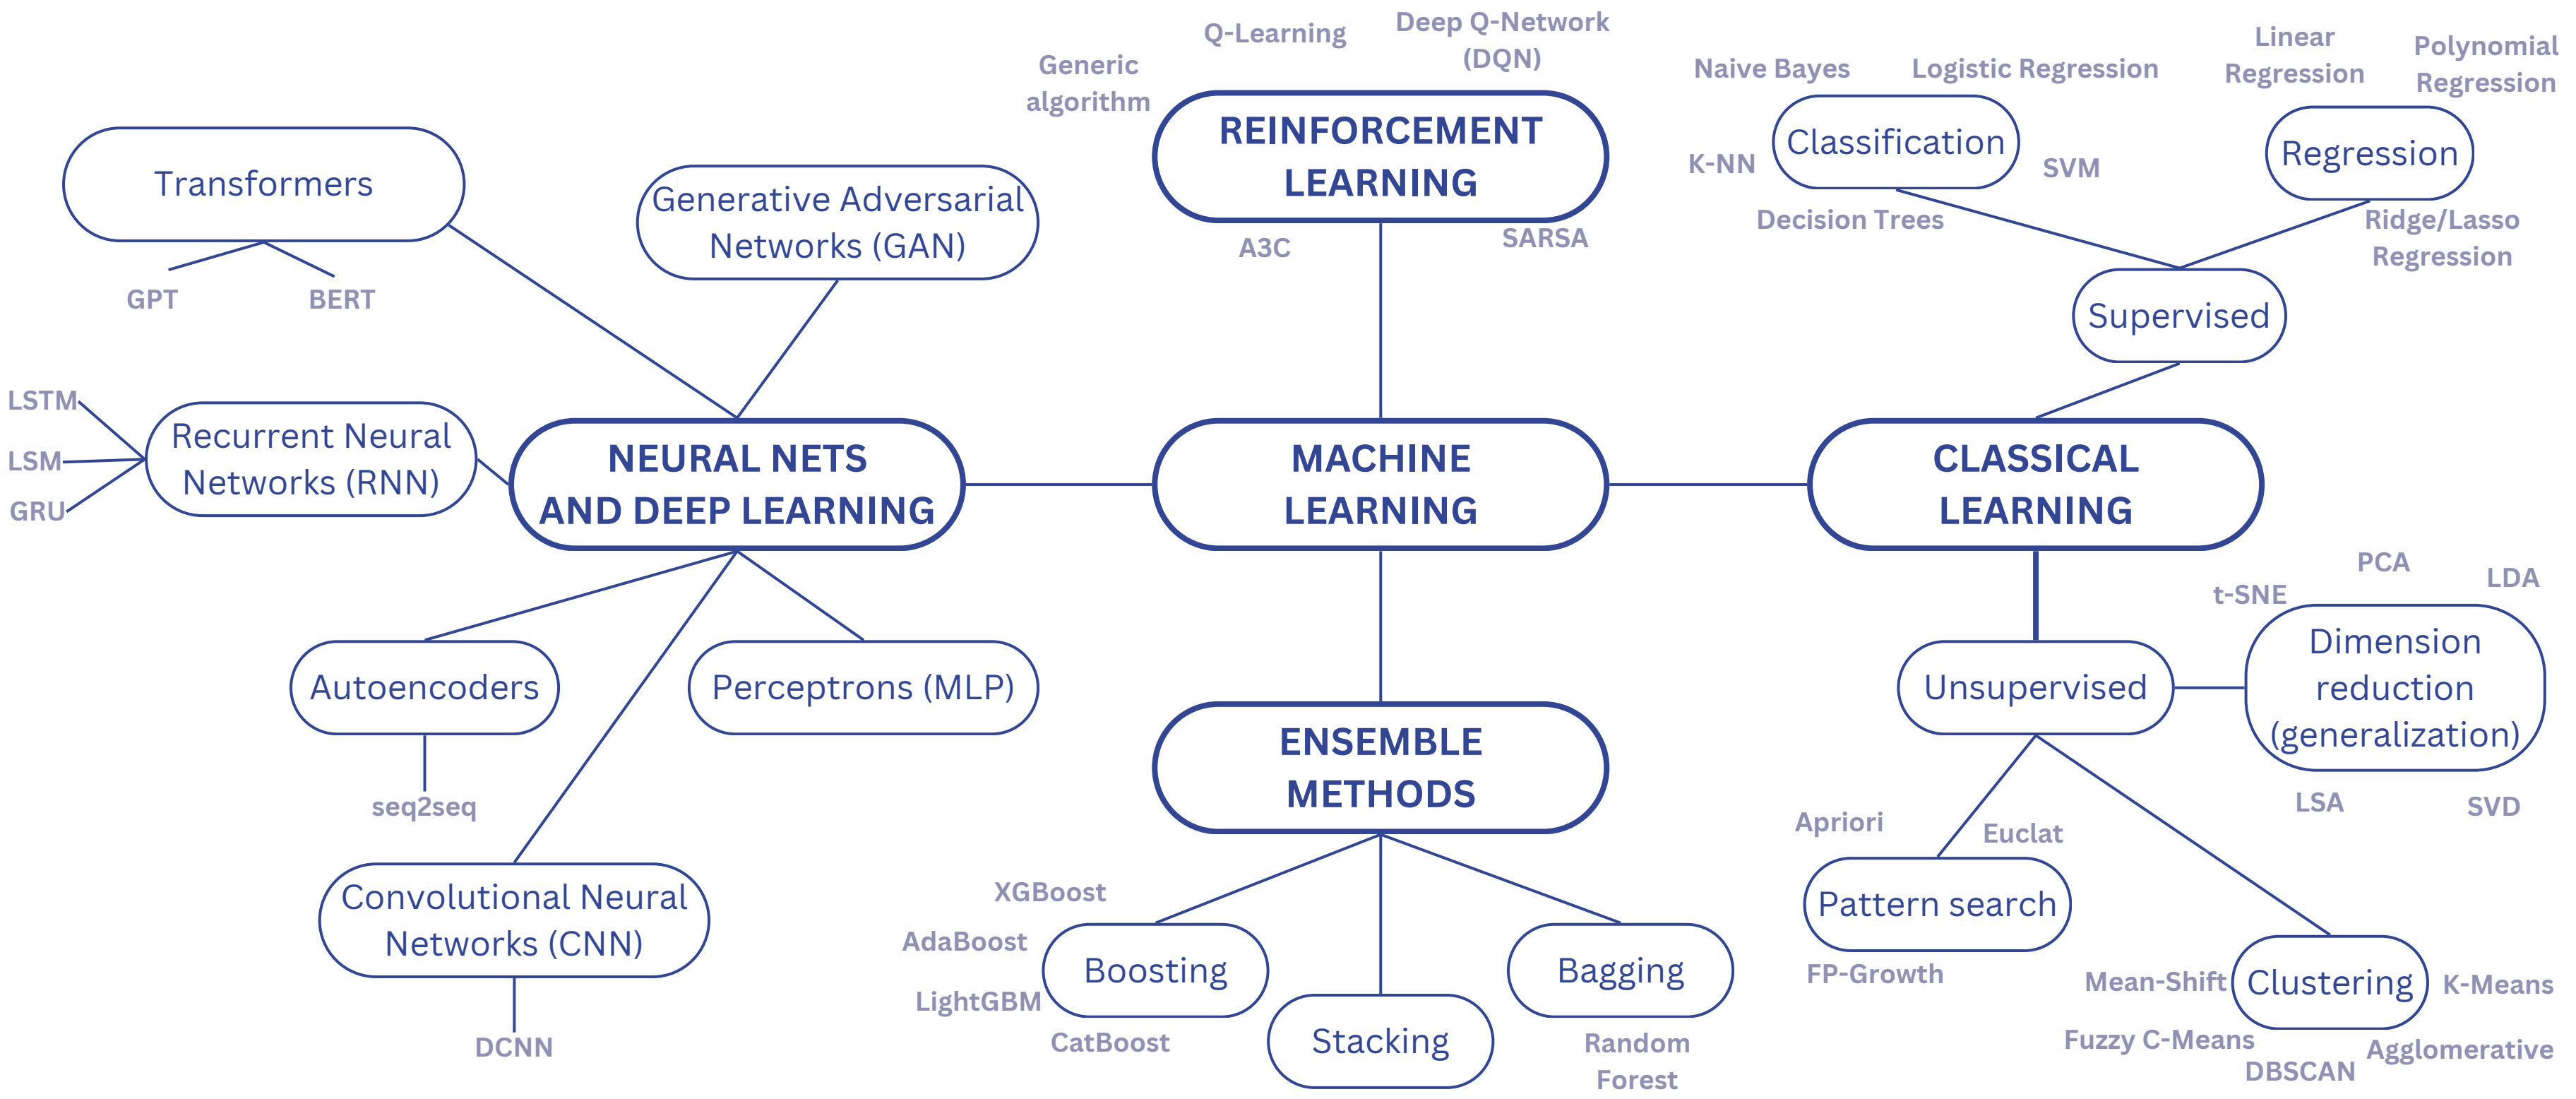
Lucrați în grupuri de 3–4. Aveți 15 minute

Scenariu: Un spital ia în considerare implementarea unui instrument AI care analizează radiografiile toracice și marchează posibilele cazuri de pneumonie pentru revizia radiologului. Furnizorul afirmă 92% acuratețe pe setul său de date de validare.

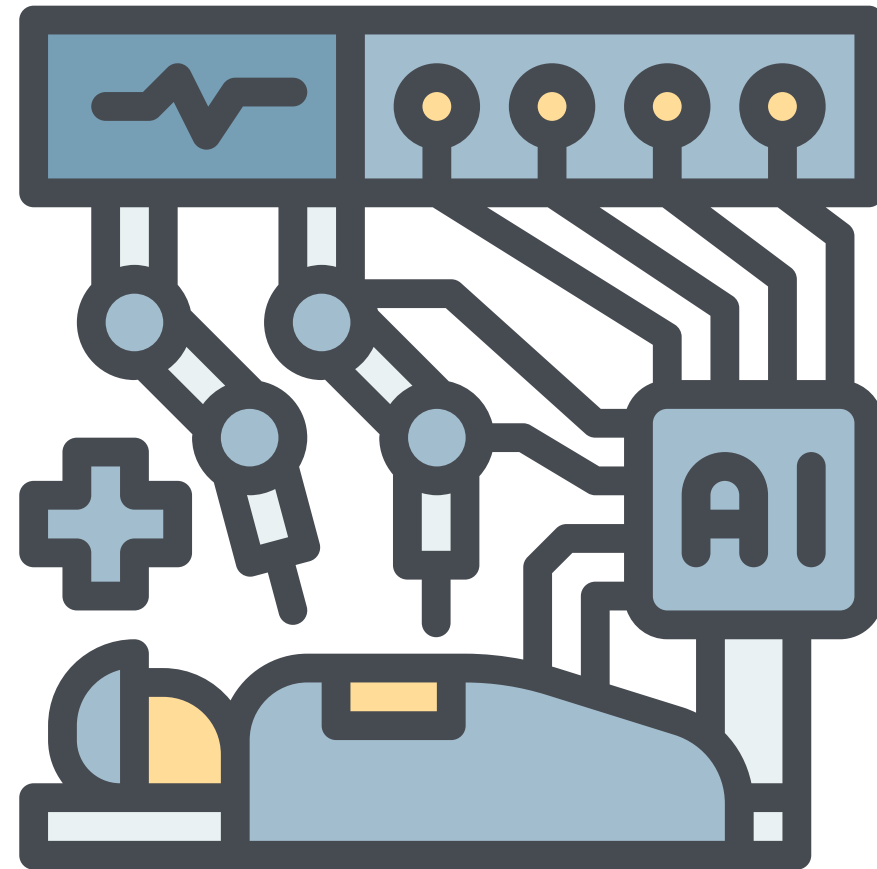
Sarcinile voastre:

1. Listați 5 întrebări pe care le-ați adresa furnizorului înainte de aprobare.
2. Ce îngrijorări privind calitatea datelor ați ridica?
3. Cum ar trebui prezentat outputul AI radiologului?
4. Ce înseamnă «human in the loop» în acest caz specific?





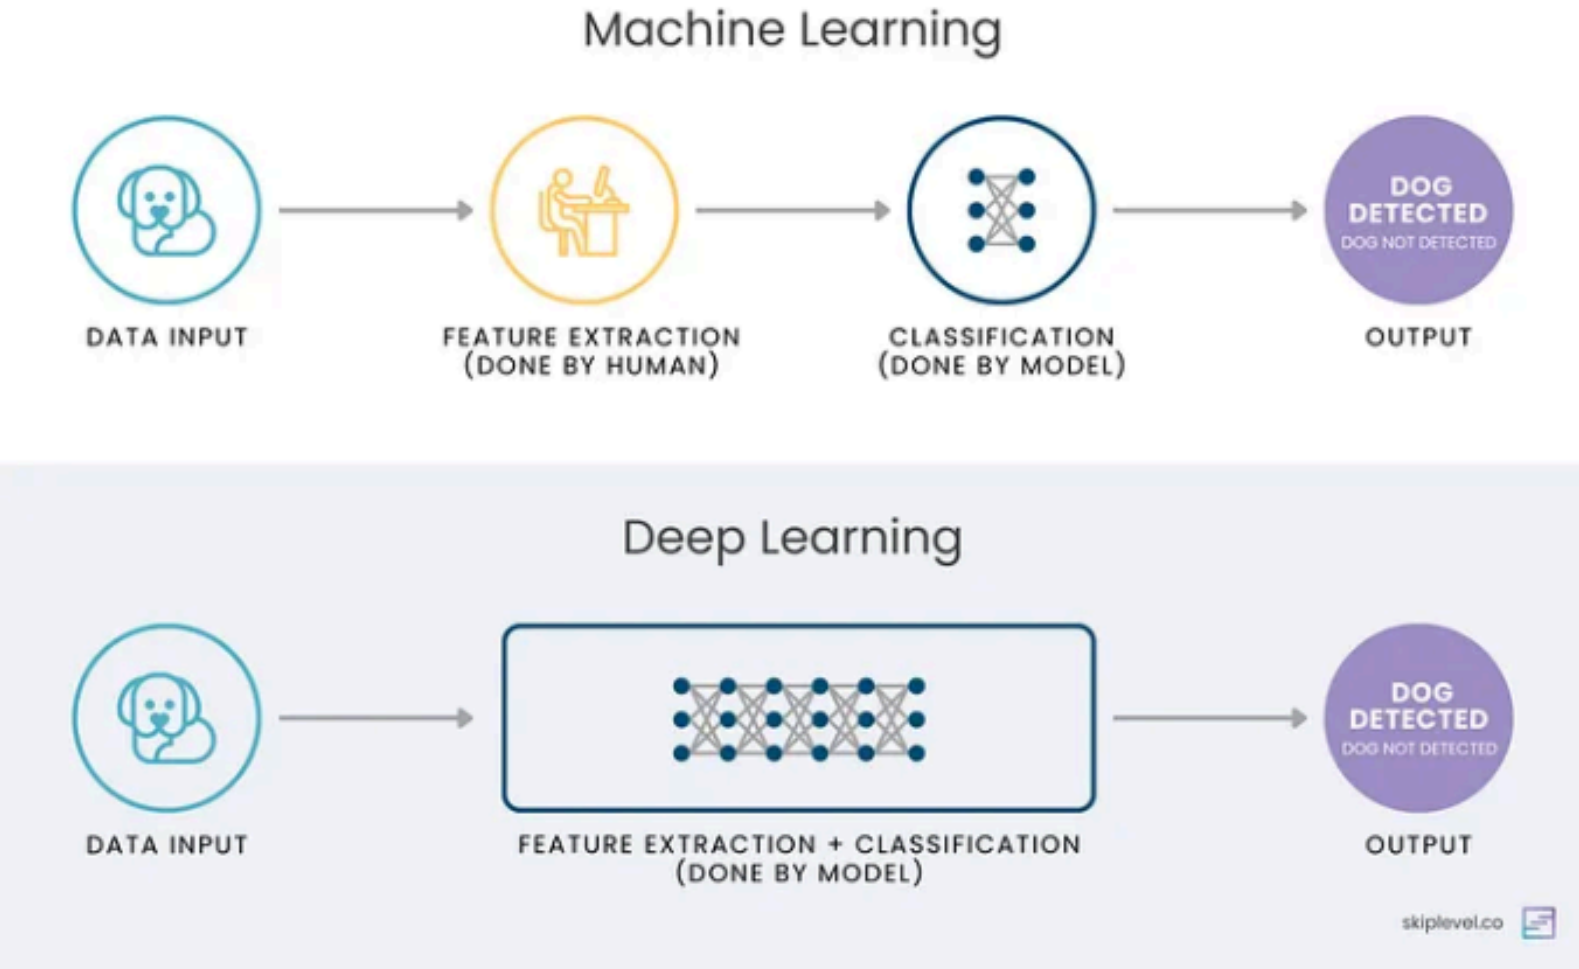
Modulul 1: Concepte Fundamentale AI în Sănătate



Key Takeaways

1. AI este o familie de tehnologii, nu un singur instrument – ML, Deep Learning și Generative AI sunt abordări distincte.
2. AI învață din date – calitatea, diversitatea și etichetarea datelor determină direct calitatea modelului.
3. Datele medicale sunt complexe, reglementate și cu mize ridicate – aplicațiile AI trebuie să țină cont de aceasta.
4. Metricile de performanță necesită context – acuratețea singură nu este suficientă; sensibilitatea și specificitatea contează.
5. Profesionistul medical rămâne esențial – AI completează judecata, nu o înlocuiește.
6. Instrumente AI reale există deja în sănătatea din România – voi veți fi inginerii care le evaluează și le construiesc.

Module 2: Aplicații AI în practica clinică și administrativă



AI TOOLS TIER LIST FOR 2026

Tier	Tools
S	OpenAI GPT-5, Gemini 2.0, Claude 3.5, GPT-5o
A	Perplexity AI, Microsoft Copilot, Google Gemini, OpenAI GPT-4o, Anthropic Claude 3.5
B	Google Gemini 1.5, OpenAI GPT-4o mini, Anthropic Claude 3.5 Haiku, Microsoft Copilot Pro, Google Gemini Advanced
E	OpenAI GPT-4o mini



Surse și Referințe

- Studiul MASAI — The Lancet, 2025 — randomized controlled trial, AI în screening mamografic
- Modelul CHIEF (Harvard Medical School) — 94% acuratețe detectie cancer, 15 tipuri, 11.000+ cazuri — Cancer journal, 2025
- Piata globala AI in sanatate — valoare 26,6 mld USD (2024), proiectie 187 mld USD (2030) — CAGR ~38,5% (crescendo.ai / StartUs Insights, 2025)
- Moratorium pe AI in sanatate Romania — studiu Goron & Chereches, Biomedical Engineering / Biomedizinische Technik, 2025
- EU AI Act (2024/1689) — cadru european pentru AI in dispozitive medicale
- Medical Device Regulation (MDR) 2017/745 — Comisia Europeana
- World Economic Forum, 7 ways AI is transforming healthcare, 2025
- FDA AI/ML Medical Devices — ~950 dispozitive aprobate la mid-2024, ~100 aprobari noi/an
- Epic Sepsis Model — implementare clinica SUA; XVision/Rayscape — Regina Maria Romania
- Moral Machine — Awad E. et al., Nature, 2018 (experiment MIT Media Lab 2014)

