

Focșa Mircea Adrian

INFORMATICA MEDICALĂ ÎN ERA DIGITALĂ

— de la date
la Inteligența Artificială



Editura „Victor Babeș”

Piața Eftimie Murgu nr. 2, cam. 316, 300041 Timișoara

Tel./Fax 0256 495 210

e-mail: evb@umft.ro

www.umft.ro/ro/organizare-evb/

Director general: Prof. univ. dr. Sorin Ursoniu

Colecția: MANUALE

Coordonatori colecție: Prof. univ. dr. Codruța Șoica

Prof. univ. dr. Daniel Lighezan

Referent științific: Prof. univ. dr. Gheorghe Ioan Mihalaș

© 2025

Toate drepturile asupra acestei ediții sunt rezervate.

Reproducerea parțială sau integrală a textului, pe orice suport, fără acordul scris al autorilor este interzisă și se va sancționa conform legilor în vigoare.

ISBN 978-606-786-518-9

Prefață

Ediția actualizată a cursului *Informatica medicală* continuă tradiția începută de Profesorul Gheorghe Ioan Mihalaș, cel care a pus bazele predării moderne a informaticii medicale la Universitatea de Medicină și Farmacie din Timișoara.

Versiunea de față nu înlocuiește contribuția sa, ci o extinde, adaptând conținutul la evoluțiile recente ale domeniului — digitalizarea actului medical, interoperabilitatea sistemelor și emergența inteligenței artificiale.

Structura volumului păstrează spiritul original: echilibrul între rigoare teoretică și utilitate practică. Într-un context medical aflat în transformare rapidă, informatica medicală rămâne o punte între știința datelor și arta îngrijirii.

Această ediție se dorește un instrument de învățare activă, dar și un omagiu adus profesorilor și cercetătorilor care au modelat această disciplină, în special Prof. Mihalaș, a cărui viziune continuă să inspire noile generații.

Nota autorului

Ediția din 2025 a acestui curs reflectă o schimbare profundă în felul în care medicina se raportează la date, tehnologie și cunoaștere. Informatica medicală nu mai este doar o disciplină de sprijin, ci un limbaj comun al medicinei moderne — cel prin care medicina clinică, cercetarea și educația converg.

În ultimii ani, apariția inteligenței artificiale generative, a micro-credențialelor digitale și a rețelelor de date deschise a transformat modul în care medicii învață, gândesc și colaborează. Prezentul volum urmărește să integreze aceste evoluții fără a pierde simplitatea necesară primului contact cu domeniul: el oferă concepte, dar și contexte, reguli, dar și reflecție critică.

Textul a fost gândit pentru studenți, dar și pentru profesioniștii care revin la informatică medicală ca la o disciplină a redescoperirii — un loc unde algoritmul întâlnește empatia, iar decizia asistată devine parte a actului medical responsabil.

Conf. univ. dr. Focșa Mircea Adrian
Catedra de Informatică și Biostatistică Medicală
Timișoara, 31.10.2025

Notă asupra ediției 2025

Ediția 2025 a cursului *Informatica medicală* propune o abordare modernă, centrată pe parcursul natural al informației în medicină: de la datele brute colectate, la interpretarea lor analitică și, în final, la decizia clinică asistată de sisteme inteligente. Structura lucrării urmează această logică în trei etape majore — *de la date, la cunoaștere și la decizie*.

Partea I – De la date la informație

(cap. 1–4)

Această primă secțiune introduce bazele conceptuale și tehnologice ale informaticii medicale. Sunt definite noțiunile fundamentale de date, informații și cunoștințe, descrisă infrastructura hardware și software a calculatoarelor medicale, precum și mecanismele de stocare și organizare a datelor – de la fișiere simple la baze de date relaționale și NoSQL. Această parte trasează harta de început a medicinei digitale, în care datele devin suportul oricărei decizii clinice.

Partea II – De la informație la cunoaștere

(cap. 5–7)

Secțiunea dedicată prelucrării datelor explorează transformarea informației în modele și relații interpretabile. Sunt prezentate metodele de analiză statistică, procesarea biosemnalelor (EKG, EEG) și prelucrarea imaginilor medicale (DICOM, PACS, segmentare, recunoaștere de forme). Această parte ilustrează cum algoritmi de filtrare, clasificare și reprezentare vizuală transformă informația numerică în cunoaștere clinică.

Partea III – De la cunoaștere la decizie

(cap. 8–10)

Ultima parte reunește aplicațiile sistemice ale informaticii medicale: arhitectura și interoperabilitatea sistemelor informatice, telemedicina, comunicarea empatică și, mai ales, evoluția deciziei medicale asistate de inteligența artificială. Capitolul final integrează noțiunile de *machine learning*, *inteligență artificială generativă (GenAI)* și *inteligență artificială generală (AGI)*, discutând totodată conceptele de *prompt engineering*, *Retrieval-Augmented Generation (RAG)* și emergența agenților autonomi. Sunt incluse și perspectivele *AI-IoT*, autoperfecționarea controlată a sistemelor și reglementările etice definite de *AI Act* și *European Health Data Space (EHDS)*.

Volumul se încheie cu un Glosar de termeni și o Bibliografie selectivă care oferă repere actuale din literatura internațională și cadrul european al sănătății digitale.

Prin această structură, cursul urmărește să ofere nu doar informații, ci și o perspectivă de ansamblu: cum se transformă datele în cunoaștere și cunoașterea în decizie, în contextul medicinei augmentate de tehnologie și inteligență artificială.

Cuprins

Partea I – De la date la informație

Capitolul 1 – Introducere în Informatica Medicală.....	1
1.1. Ce este informatica medicală?	2
1.2. Informatica medicală ca disciplină interdisciplinară	3
1.3. Evoluția informaticii medicale.....	4
1.4. Aplicațiile clasice ale calculatoarelor în domeniul medical.....	5
1.5. Medicina pacientului digital	7
1.6. Domenii emergente ale informaticii medicale	9
1.7. Provocări și perspective	13
Capitolul 2 – Arhitectura sistemelor de calcul	17
2.1. Introducere – calculatorul ca instrument al medicinei digitale.....	17
2.2. Hardware și software – concepte fundamentale	18
2.3. Arhitectura clasică a calculatoarelor	18
2.4. Evoluția microprocesoarelor	19
2.5. Procesoare neuronale (NPU).....	20
2.6. Calculatoarele cuantice – principii și provocări.....	22
2.7. Software și sisteme de operare.....	24
2.8 Cloud computing în medicina digitală.....	26
2.9. Arhitectura calculatoarelor în era AI și a medicinei digitale	27
De reținut	28
Capitolul 3 – Date, informații și cunoștințe medicale.....	29
3.1. Teoria informației.....	29
3.2. Date, informații și cunoștințe în medicină	38
3.3. Informația medicală în spațiul virtual	41
Capitolul 4 – Stocarea datelor.....	46
4.1. Fișiere de date	47

4.2. Baze de date	49
4.2.1. Baze de date relaționale	52
4.2.2. Baze de date NoSQL.....	54
4.3. Sisteme de gestiune a bazelor de date (SGBD)	55
Partea II – De la informație la cunoaștere	
Capitolul 5 – Prelucrarea datelor numerice și calitative	63
5.1. Tipuri de date medicale.....	66
5.2. Organizarea și reprezentarea datelor.....	68
5.3. Analiza univariată	70
5.4. Inferența statistică	74
5.4. Analiza bivariată	75
5.5. Analiza multivariată	78
Capitolul 6 – Prelucrarea biosemnalelor.....	82
6.1. Definiție și clasificarea biosemnalelor.....	82
6.2. Sistemele de achiziție a biosemnalelor	84
6.3. Conversia analog–numerică a biosemnalelor	85
6.4. Reprezentarea frecvențială a biosemnalelor	88
6.5. Filtrarea semnalului	90
6.6. Analiza semnalelor periodice – semnalul EKG	93
6.7 Analiza semnalelor neperiodice - EEG	98
Capitolul 7. Prelucrarea imaginilor medicale	102
7.1. Noțiuni introductive	102
7.2. Tipuri de imagini.....	105
7.3. Reprezentarea culorilor.....	106
7.4. Achiziția imaginilor biomedicale.....	107
7.5. Standardul DICOM și sistemele PACS.....	111
7.6. Etapele prelucrării imaginilor	112

7.7. Preprocesarea imaginilor	114
7.8. Segmentarea imaginilor	117
7.9. Descrierea și recunoașterea imaginilor	121
7.10. Aplicații avansate — Realitate virtuală, augmentată și mixtă	124
Partea III – De la cunoaștere la decizie	
Capitolul 8 – Sisteme informatice medicale	129
8.1. Informația medicală pe nivele de asistență	129
8.2. Sisteme informaționale și sisteme informatice	131
8.3. Dosarul electronic de sănătate (EHR).....	136
8.4. Interoperabilitatea sistemelor informatice medicale.....	140
8.5. Spațiul European al Datelor privind Sănătatea (EHDS)	150
8.6. Securitatea și protecția datelor în sistemele informatice medicale ..	153
8.7. Direcții de dezvoltare	158
Capitolul 9 – Telemedicina	163
9.1 Definiție, delimitări și context	163
9.2 Arhitectura sistemelor de telemedicină	164
9.3 Aplicații clinice reprezentative	167
9.4 Cadrul juridic al telemedicinii în România	169
9.5 Securitate, confidențialitate și fiabilitate.....	171
9.6 Aspecte etice și de comunicare	172
9.7 Direcții emergente.....	175
Capitolul 10 – Decizia medicală asistată și aplicații ale inteligenței artificiale în medicină.....	179
10.1. Rolul deciziei medicale asistate	179
10.2. Metode logice de decizie asistată.....	181
10.3. Metode statistice și de recunoaștere a tiparelor	183
10.4. Metode euristice – sistemele expert.....	186

10.5. Calitatea deciziei și validarea sistemelor	188
10.6. Machine Learning - învățarea automată	192
10.7. Dimensiunile operaționale ale inteligenței artificiale	194
10.8. Inteligența artificială generativă	196
10.9. Inteligența artificială generală și tendințele viitoare	199
 Glosar de termeni	 202
Bibliografie selectivă	204

Partea I

De la date la informație

Capitolul 1 – Introducere în Informatica Medicală

1.1. Ce este informatica medicală?

Informatica medicală este o disciplină relativ tânără, dar cu un impact tot mai vizibil asupra practicii medicale. Ea se află la intersecția dintre medicină, informatică și știința datelor, având ca obiect de studiu **informația medicală**: cum este generată, colectată, stocată, transmisă, prelucrată și utilizată pentru a sprijini activitatea medicală și cercetarea științifică.

Într-o lume în care volumul datelor medicale se dublează la fiecare câțiva ani, devine imposibil pentru un medic sau chiar pentru o echipă de specialiști să le gestioneze în mod clasic. Fiecare pacient generează mii de date – de la istoricul medical și investigațiile paraclinice, la imagistica medicală și analizele genomice. În plus, noile tehnologii (ceasuri inteligente, senzori de monitorizare, aplicații mobile) produc fluxuri continue de informații.

Aici intervine rolul **inteligenței artificiale (AI)**, care, integrată în informatica medicală, are capacitatea de a transforma aceste date brute în informații utile pentru diagnostic, tratament și prevenție. Dacă până recent informatica medicală era văzută ca un suport tehnologic pentru arhivarea și transmiterea datelor, astăzi ea devine o știință centrată pe AI, unde algoritmi nu doar sprijină, ci și **participă activ la procesul medical**.

Inteligenta artificială reprezintă ansamblul tehnologiilor capabile să imite funcții cognitive umane precum raționamentul, învățarea, recunoașterea tiparelor și luarea deciziilor. În medicină, rolul său nu se limitează la un simplu instrument de procesare a datelor, ci se extinde până la **parteneriatul cu medicul**.

 Spre exemplu, un algoritm de recunoaștere a imaginilor poate analiza sute de radiografii pulmonare într-o oră, identificând cu o precizie foarte mare leziuni sugestive pentru tuberculoză sau cancer incipient. Un medic radiolog ar putea ajunge la aceeași concluzie, însă cu un timp mult mai mare de procesare și cu o oboseală acumulată care ar putea afecta acuratețea. AI, în schimb, nu obosește, poate compara cazuri similare din baze de date internaționale și poate furniza medicului un raport cu probabilități de diagnostic.

Așadar, AI devine elementul central al informaticii medicale moderne pentru că oferă:

- **viteză** în procesarea unor volume uriașe de date,
- **precizie** prin identificarea unor tipare invizibile ochiului uman,
- **personalizare** a tratamentelor, în funcție de profilul individual al pacientului,
- **sprijin decizional** pentru medic, fără a-i substitui rolul etic și profesional.

1.2. Informatica medicală ca disciplină interdisciplinară

Informatica medicală nu este o disciplină izolată, ci rezultatul unei colaborări continue între mai multe domenii.

Pe de o parte, ea se sprijină pe **medicină**, care furnizează contextul clinic, întrebările de cercetare și nevoile reale ale pacienților. Orice algoritm sau sistem informatic este valid doar dacă răspunde unor probleme medicale concrete.

Pe de altă parte, are rădăcini puternice în **informatică**, de unde preia metodele de stocare, procesare și transmitere a datelor. Algoritmii de inteligență artificială, bazele de date și rețelele informatice sunt instrumente esențiale fără de care medicina digitală nu ar fi posibilă.

Un al treilea pilon îl reprezintă **știința datelor**, care oferă tehnici de analiză statistică, machine learning și interpretare a volumelor uriașe de informații generate de pacienți, investigații și cercetări. Prin data science, medicii pot trece de la simple observații individuale la modele predictive aplicabile la nivel de populație.

Nu în ultimul rând, informatica medicală este strâns legată de **etică**. Probleme precum confidențialitatea datelor, drepturile pacientului, echitatea accesului la tehnologie și responsabilitatea în utilizarea AI impun un cadru etic solid. Fără acest fundament, riscul de abuzuri sau discriminări ar fi semnificativ.

Astfel, informatica medicală este o veritabilă **disciplină interdisciplinară**, în care cunoștințele medicale, competențele tehnice și reflecția etică se completează reciproc pentru a transforma practica medicală într-o știință a viitorului.

1.3. Evoluția informaticii medicale

Informatica medicală s-a dezvoltat treptat, reflectând transformările tehnologice ale ultimelor decenii. În anii 1960 și 1970, primele aplicații au vizat gestionarea datelor medicale prin sisteme informatizate destinate laboratoarelor și bazelor clinice. Aceste instrumente rudimentare aveau rolul de a organiza informațiile și de a reduce erorile asociate evidenței pe suport de hârtie.

În deceniul următor, odată cu extinderea rețelelor informatice, au apărut primele experimente de telemedicină, prin care se încerca transmiterea datelor medicale la distanță. Era o perioadă dominată de preocuparea pentru conectivitate, iar scopul principal era facilitarea schimbului de informații între centre universitare și spitale periferice.

Anii 1990 au adus o schimbare de paradigmă, odată cu introducerea conceptului de telematică în sănătate. În această etapă, telecomunicațiile și informatica s-au îmbinat, iar primele dosare electronice de sănătate au început să fie implementate. Pentru prima dată, datele unui pacient puteau fi integrate într-un fișier digital unitar, accesibil profesioniștilor din mai multe locații.

În anii 2000, digitalizarea a fost accelerată de dezvoltarea noțiunii de eHealth, care a extins utilizarea tehnologiilor informatice către diagnostic, tratament și sănătatea publică. Această perioadă a coincis cu apariția telefoanelor mobile inteligente, ceea ce a permis nașterea aplicațiilor de mHealth, orientate spre monitorizarea pacienților și educația pentru sănătate.

Un alt moment decisiv s-a produs în anii 2010, când au fost implementate pe scară largă dosarele electronice de sănătate și rețelele electronice. În paralel, a devenit evident rolul Big Data în medicină, odată cu posibilitatea de a analiza volume imense de informații provenite din imagistică, genomică și date epidemiologice.

Deceniul actual marchează maturizarea inteligenței artificiale și transformarea ei în element central al informaticii medicale. Algoritmii de învățare automată și rețelele neuronale nu mai sunt simple instrumente de sprijin, ci parteneri activi în diagnostic, analiză imagistică și medicină personalizată. Tot în

această etapă, rețeaua dispozitivelor medicale conectate, cunoscută sub numele de Internetul Obiectelor Medicale (Internet of Medical Things), permite monitorizarea continuă și transmiterea în timp real a datelor fiziologice către medici și platforme AI.

Această evoluție cronologică arată o trecere graduală de la simpla digitalizare a informațiilor către o medicină inteligentă, susținută de AI, unde datele nu mai sunt doar înregistrate, ci și interpretate, pentru a sprijini deciziile clinice și a oferi tratamente personalizate.




Figura 1.1. Evoluția informaticii medicale din 1960 până în prezent

1.4. Aplicațiile clasice ale calculatoarelor în domeniul medical

Informatica medicală nu se limitează la colectarea datelor, ci se extinde în mai multe domenii complementare, care acoperă atât practica clinică, cât și cercetarea.

Un prim domeniu este **prelucrarea datelor**, unde metodele de biostatistică și bazele de date medicale sunt esențiale pentru organizarea și interpretarea informațiilor clinice. De la analize epidemiologice până la studiile clinice randomizate, aceste instrumente permit extragerea de concluzii valide și fundamentarea deciziilor medicale.

Un al doilea domeniu este **asistarea investigațiilor medicale**. Aici, calculatoarele sunt folosite pentru prelucrarea semnalelor și a imaginilor medicale, fie că este vorba de electrocardiograme sau de imagistică RMN. Algoritmii de inteligență artificială pot îmbunătăți calitatea imaginilor, pot reduce zgomotul și pot identifica automat anomalii greu de sesizat de ochiul uman.

Un domeniu important al informaticii medicale clasice îl reprezintă **sistemele expert**. Acestea sunt programe concepute pentru a reproduce raționamentul unui specialist uman, pe baza unui set de reguli și a unei baze de cunoștințe. Printre exemplele cele mai cunoscute se numără:

- **MYCIN** (anul 1972) – dezvoltat la Universitatea Stanford pentru diagnosticul infecțiilor bacteriene și recomandarea tratamentului antibiotic.
- **Internist-1** (anul 1970) – sistem pentru diagnostic diferențial în medicină internă, capabil să gestioneze peste 500 de boli.
- **DXplain** (anul 1987, Massachusetts General Hospital) – un sistem expert educațional care oferă liste de diagnostice posibile în funcție de simptome și analize clinice.

Aceste sisteme au demonstrat potențialul calculatoarelor de a sprijini medicul în procesul decizional, chiar dacă uneori limitările tehnice sau lipsa de integrare cu practica clinică au redus impactul lor direct.

Astăzi, multe dintre conceptele sistemelor expert au fost integrate în **module de decizie asistată (Clinical Decision Support Systems – CDSS)**, care fac parte din sistemele informatice moderne, cum ar fi dosarele electronice de sănătate. Aceste module nu mai funcționează izolat, ci sunt integrate în platforme clinice, semnalând interacțiuni medicamentoase, recomandând investigații suplimentare sau sugerând posibile diagnostice.

Un al patrulea domeniu este **organizarea activității medicale**, unde sistemele informatice integrează fluxurile de date și resursele spitalicești. Exemplele includ dosarul electronic de sănătate, cardul de sănătate și platformele informatice integrate, care facilitează coordonarea actului medical și reduc birocrația.

Nu în ultimul rând, informatica medicală are un rol central în **asistarea cercetării medicale**. Documentarea asistată prin baze de date internaționale, modelarea proceselor biologice și simulările computerizate deschid noi perspective pentru înțelegerea mecanismelor bolilor și dezvoltarea de tratamente inovatoare.

Astfel, informatica medicală acționează simultan la nivel clinic, organizațional și de cercetare, transformând modul în care datele medicale sunt generate, prelucrate și utilizate.

1.5. Medicina pacientului digital

Odată cu digitalizarea accelerată a societății, medicina a intrat într-o etapă de transformare fundamentală, în care pacientul nu mai este doar receptor al actului medical, ci și un generator activ de date și un participant direct în procesul de îngrijire. Această paradigmă este cunoscută sub numele de **medicina pacientului digital**.

Pacientul digital este înzestrat cu o gamă largă de dispozitive și aplicații care permit monitorizarea continuă a stării de sănătate. Ceasurile inteligente, brățările de fitness, glucometrele conectate sau senzori implantați în organism furnizează permanent date despre ritmul cardiac, nivelul glicemiei, calitatea somnului sau activitatea fizică. Aceste informații sunt transmise către platforme integrate, unde pot fi analizate în timp real de către algoritmi de inteligență artificială.

Un element central al acestei abordări îl constituie **Internetul Obiectelor Medicale** (Internet of Medical Things - IoMT) – rețeaua tot mai vastă de dispozitive medicale conectate. IoMT face posibilă nu doar colectarea de date la scară largă, ci și corelarea acestora cu dosarele electronice de sănătate, istoricul familial și datele de mediu. În acest fel, medicul are acces la o imagine complexă și actualizată a pacientului, depășind limitele consultațiilor punctuale din trecut.

Medicina pacientului digital presupune, de asemenea, o schimbare de rol: pacientul devine un **partener activ** în managementul propriei sănătăți. Conceptul de self-monitoring și educația pentru sănătate oferă individului autonomie și responsabilitate, încurajându-l să își urmărească parametrii biologici, să își ajusteze comportamentele și să ia decizii informate.

Caz clinic

MP, un pacient de 58 de ani, diagnosticat cu insuficiență cardiacă, utilizează un set de **dispozitive purtabile conectate la IoMT**: un ceas inteligent care monitorizează ritmul cardiac și nivelul de oxigen, o brățară pentru tensiunea arterială și un senzor de greutate corporală conectat la aplicația mobilă.

Datele sunt transmise automat către platforma digitală a spitalului, unde un algoritm de **inteligență artificială** analizează zilnic variațiile parametrilor. Într-o dimineață, sistemul detectează o creștere rapidă a greutății și o scădere a saturației oxigenului — semne subtile de acumulare de lichid și decompensare cardiacă.

Platforma trimite o alertă medicului curant, care contactează imediat pacientul. După evaluarea la distanță, MP primește ajustarea tratamentului diuretic și recomandarea de a veni la control în următoarele zile.

Această **intervenție timpurie** a prevenit o spitalizare de urgență și a arătat cum medicina pacientului digital transformă actul medical într-un proces continuu, bazat pe monitorizare în timp real și sprijinul AI.

Din perspectivă clinică, integrarea datelor generate de pacient cu analiza Big Data și cu algoritmi de învățare automată permite trecerea de la o medicină reactivă, bazată pe tratamentul bolii, la o medicină proactivă, centrată pe predicția și prevenția riscurilor. Astfel, inteligența artificială poate identifica tipare subtile în datele pacienților și poate semnala riscuri înainte de apariția simptomelor, facilitând intervenții timpurii și personalizate.

Desigur, această transformare ridică și provocări. **Confidențialitatea datelor**, securitatea rețelelor medicale și riscul de suprasolicitare informațională sunt aspecte care trebuie abordate prin reglementări clare și prin tehnologii robuste de protecție. În același timp, este esențial ca digitalizarea să nu adâncească inegalitățile de acces, asigurându-se că instrumentele digitale sunt disponibile tuturor pacienților, nu doar celor privilegiați.




Fig. 1.2. Fluxul informației medicale în contextul pacientului digital

În concluzie, medicina pacientului digital marchează o tranziție majoră în practica medicală: de la o medicină centrată pe instituții și pe medic, la una centrată pe pacient, susținută de tehnologie, conectivitate și inteligență artificială. Această schimbare redefineste relația medic–pacient și deschide calea către îngrijiri de sănătate mai personalizate, mai predictive și mai participative.

1.6. Domenii emergente ale informaticii medicale

Inteligența artificială nu înlocuiește domeniile tradiționale ale informaticii medicale, ci le potențează. Ea devine un factor integrator, accelerând progresul în telemedicină, eHealth, Big Data, IoMT și medicina personalizată.

 Exemple clinice, precum monitorizarea pacienților diabetici prin senzori conectați la algoritmi AI, arată modul concret în care tehnologia sprijină practica medicală zilnică.

a) eHealth și mHealth

eHealth – Sănătatea electronică. eHealth (e-Sănătate) desemnează ansamblul serviciilor medicale furnizate prin intermediul tehnologiilor digitale. Este un concept mai amplu decât mHealth, deoarece nu se limitează la telefonul mobil sau dispozitive portabile, ci include infrastructura digitală de la nivel instituțional, național și chiar internațional.

eHealth acoperă o gamă largă de domenii: diagnostic și tratament la distanță, cercetare medicală, educarea profesioniștilor și a pacienților, monitorizarea epidemiologică și sprijinirea sănătății publice. Prin eHealth, datele medicale devin accesibile nu doar medicilor și pacienților individuali, ci și autorităților sanitare, care le pot folosi pentru planificarea resurselor și prevenirea bolilor la nivel populațional.

Un exemplu uzual îl reprezintă **portalurile electronice pentru pacienți**, unde aceștia își pot accesa rezultatele analizelor, își pot programa consultații sau pot comunica direct cu medicul prin mesagerie securizată. Acest tip de platformă reduce deplasările inutile, scurtează timpii de așteptare și sporește transparența relației medic–pacient.

În plus, eHealth include și sisteme de **rețetă electronică** și **dosar electronic de sănătate (EHR)**. Acestea facilitează partajarea datelor între diferiți furnizori de servicii medicale și previn erorile prin centralizarea istoricului medical al pacientului. De exemplu, un medic de familie poate accesa rapid istoricul de analize și tratamente al pacientului, chiar dacă acesta a fost consultat în alte clinici sau spitale.

Un alt domeniu important este cel al **educației și formării medicale**, unde eHealth furnizează platforme de e-learning pentru studenți și cursuri de formare continuă pentru medici. De asemenea, oferă resurse educaționale digitale pentru pacienți, ajutându-i să înțeleagă mai bine bolile și tratamentele.

Nu în ultimul rând, eHealth are un rol crucial în **sănătatea publică**, prin sistemele informatice de supraveghere epidemiologică. Acestea pot detecta rapid focare de boală și pot contribui la gestionarea eficientă a situațiilor de urgență, așa cum s-a demonstrat în timpul pandemiei COVID-19.

Astfel, eHealth reprezintă infrastructura digitală care susține medicina modernă, conectând pacienți, profesioniști și autorități într-un ecosistem integrat.

mHealth – Sănătatea mobilă. Un domeniu în continuă expansiune al informaticii medicale este mHealth (mobile health), adică utilizarea telefoanelor inteligente, tabletelor și dispozitivelor portabile pentru monitorizarea și sprijinirea sănătății. Aceste instrumente transformă telefonul mobil într-un partener de sănătate personal, care colectează date, oferă recomandări și conectează utilizatorul cu rețeaua medicală.

Un tip de aplicații îl reprezintă cele destinate **urmăririi activității fizice și a parametrilor de sănătate**. Platforme precum *Fitbit* sau *Apple Health* înregistrează pașii zilnici, ritmul cardiac, calitatea somnului și nivelul de activitate. Datele sunt sincronizate automat și pot fi folosite pentru ajustarea stilului de viață. De exemplu, o persoană poate purta un ceas inteligent care îi monitorizează activitatea zilnică și îi trimite alerte personalizate pentru a o încuraja să rămână activă.

Alte aplicații sprijină **gestionarea medicației**. Programe precum *Medisafe* le amintesc pacienților să își ia tratamentul la ore fixe și pot transmite notificări familiei sau medicului dacă pacientul nu respectă schema. Un exemplu concret este cel al unui pacient vârstnic cu hipertensiune și diabet, care folosește *Medisafe* pentru a primi notificări zilnice legate de administrarea medicamentelor, reducând astfel riscul de omisiuni.

Un alt domeniu emergent este **monitorizarea sănătății materne și a nou-născuților**. Aplicații precum *Babyscripts* permit gravidelor să își înregistreze tensiunea arterială, greutatea și alți parametri, care sunt trimiși automat către medicul curant. Astfel, o femeie însărcinată își poate măsura tensiunea acasă și transmite rezultatele în timp real către obstetrician, care poate interveni prompt dacă apar probleme.

În fine, **aplicațiile pentru sănătatea mintală** devin din ce în ce mai utilizate. Platforme precum *Headspace* sau *Calm* oferă exerciții de meditație și tehnici de reducere a stresului, ajutând utilizatorii să își gestioneze anxietatea și să își mențină echilibrul psihic. Spre exemplu, un utilizator poate apela zilnic la *Headspace* pentru sesiuni de meditație ghidată, cu efecte pozitive asupra sănătății mentale și calității vieții.

Astfel, mHealth extinde accesul la servicii medicale și de prevenție, încurajează auto-monitorizarea și responsabilizarea pacientului și oferă medicilor date valoroase pentru o îngrijire personalizată.

b) Telemedicină și telesănătate

Dezvoltarea tehnologiilor de comunicații a făcut posibilă furnizarea de servicii medicale dincolo de limitele fizice ale cabinetului sau spitalului. În acest context, s-au conturat două concepte apropiate, dar distincte: **telemedicina** și **telesănătatea**.

Telemedicina se referă strict la actul medical realizat la distanță. Ea include consultațiile prin videoconferință, transmiterea și interpretarea de investigații paraclinice (radiografii, analize de laborator), precum și monitorizarea continuă a pacienților cronici prin dispozitive conectate. Esențial este faptul că telemedicina presupune o **interacțiune clinică directă** între medic și pacient, chiar dacă cei doi se află în locații diferite.

Telesănătatea, în schimb, are o sferă mai largă. Ea desemnează ansamblul serviciilor de sănătate furnizate la distanță prin intermediul tehnologiilor digitale. Pe lângă componenta clinică, telesănătatea include educația pentru sănătate, consilierea psihologică, managementul bolilor cronice, sprijinul social și orice alte servicii care contribuie la îmbunătățirea stării de sănătate a individului sau comunității. Astfel, telesănătatea integrează atât telemedicina, cât și serviciile conexe actului medical.

Prin urmare, telemedicina reprezintă nucleul clinic al telesănătății, în timp ce telesănătatea reflectă un ecosistem mai cuprinzător, menit să asigure accesul la informații, educație și sprijin medical indiferent de locul unde se află pacientul.

c) Big Data medical

Big Data se referă la ansamblul de date extrem de voluminoase, provenite din multiple surse: fișe electronice de sănătate, imagistică medicală, genomuri, aplicații mobile, senzori purtabili.

AI este instrumentul indispensabil pentru a descoperi sensul acestor date. Un exemplu este analiza genomului pentru a identifica predispoziții genetice la anumite boli. Algoritmii de învățare automată pot compara secvențele genetice ale unui pacient cu milioane de alte secvențe existente în baze de date, identificând riscuri de cancer sau boli rare.

De asemenea, în domeniul sănătății publice, AI poate analiza date epidemiologice în timp real pentru a anticipa focare de gripă sau alte infecții și pentru a sprijini autoritățile în luarea de decizii rapide.

d) Internetul Obiectelor Medicale (IoMT)

IoMT reprezintă rețeaua de dispozitive medicale conectate la internet. Acestea pot fi senzori purtabili (ceasuri inteligente, glucometre conectate), dispozitive implantabile (stimulatoare cardiace, pompe de insulină) sau sisteme complexe precum roboții chirurgicali.

Rolul AI este de a integra și analiza fluxurile continue de date generate de aceste dispozitive. De exemplu, o pompă de insulină conectată poate ajusta automat doza administrată pe baza valorilor glicemiei transmise în timp real de un senzor. Această integrare reduce riscul de hipoglicemie severă și oferă pacientului o calitate a vieții net superioară.

e) Medicina personalizată

Unul dintre cele mai mari avantaje aduse de AI este trecerea de la medicina „one size fits all” la **medicina personalizată**.

Fiecare individ are un profil unic, determinat de structura genetică, mediul de viață și comportamentele de sănătate. AI permite analiza simultană a acestor factori pentru a recomanda tratamente specifice.

🔗 De exemplu, în oncologie, algoritmi AI pot integra date histopatologice, imagistice și genomice pentru a sugera terapia cea mai eficientă pentru un anumit tip de cancer. Astfel, doi pacienți cu aceeași formă de cancer pot primi tratamente diferite, în funcție de particularitățile biologice ale tumorii lor.

1.7. Provocări și perspective

Din perspectivă etică, utilizarea AI în medicină ridică întrebări legate de responsabilitate și echitate. Cine răspunde atunci când o decizie algoritmică duce la un diagnostic greșit? Cum pot fi reduse bias-urile care apar din seturi de date incomplete sau neechilibrate? Aceste dileme fac parte din provocările actuale și trebuie discutate în paralel cu beneficiile AI.

Confidențialitatea datelor medicale reprezintă una dintre cele mai mari preocupări. Dosarele electronice de sănătate, imaginile medicale și datele generate de dispozitivele portabile conțin informații extrem de sensibile. O eventuală breșă de securitate ar putea expune istoricul medical al pacienților către persoane sau instituții neautorizate. De aceea, implementarea AI în medicină trebuie să fie însoțită de măsuri stricte de protecție a datelor, criptare și reglementări legale clare.

Un alt aspect critic este **bias-ul algoritmic**. Inteligența artificială „învață” din date, iar dacă acestea nu sunt suficient de diverse și reprezentative, rezultatele pot fi distorsionate. De exemplu, un algoritm antrenat predominant pe date dintr-o anumită populație poate genera erori atunci când este aplicat pe pacienți din alte regiuni sau cu alte caracteristici demografice. Aceasta poate duce la inechități în diagnostic și tratament, ceea ce subliniază necesitatea unor seturi de date echilibrate și transparente.

În plus, trebuie regândit **rolul medicului** în contextul utilizării AI. Deși algoritmi pot sprijini procesul de diagnostic sau pot sugera opțiuni terapeutice, decizia finală trebuie să rămână una umană, ghidată de responsabilitatea etică și profesională a clinicianului. AI trebuie privită ca un instrument de sprijin, nu ca un substitut al medicului.

Nu în ultimul rând, **accesibilitatea** este o provocare majoră. Nu toate sistemele de sănătate dispun de infrastructura digitală necesară pentru a integra soluții AI. În țările cu resurse limitate, lipsa conexiunilor stabile la internet sau a echipamentelor moderne poate împiedica implementarea tehnologiilor avansate. În același timp, există riscul ca AI să adâncească inegalitățile dintre sistemele de sănătate bine finanțate și cele aflate în dificultate.

Dincolo de aceste provocări, direcțiile de dezvoltare ale informaticii medicale deschid perspective inovatoare, dintre care medicina de precizie, digital twins și calculul cuantic sunt cele mai promițătoare.

Viitorul predicției riscurilor medicale constă în tranziția de la scorurile generale, bazate pe populație, la **predicții de risc personalizate**, unde un număr mare de variabile individuale sunt integrate de-a lungul întregii vieți a pacientului. Inteligența artificială, cu capacitatea ei de a procesa rapid volume uriașe de date, a deschis deja calea către modele de predicție mai precise decât cele statistice tradiționale. În prezent, majoritatea algoritmilor de învățare automată se bazează pe date provenite din variabile demografice, biomarkeri sau imagistică.

Următoarea frontieră o reprezintă **medicina de precizie**, care va integra simultan informații din genetică, proteomică, metabolomică, lipidomică și imagistică, la care se adaugă datele furnizate de dispozitivele portabile și de

dosarele electronice. Astfel, fiecare pacient va beneficia de un profil digital unic, pe baza căruia se pot anticipa riscuri și recomanda terapii personalizate. Medicina nu va mai trata doar boala, ci va adapta intervențiile la contextul biologic și social al fiecărei persoane.




Fig. 1.4. Medicina personalizată facilitată de „geamănul digital”

Un alt concept emergent este cel de **digital twin (geamăn digital)** – replica digitală a pacientului, construită prin integrarea datelor biologice, clinice și comportamentale (fig. 1.4). Acest „geamăn digital” poate fi folosit pentru simularea evoluției bolilor sau pentru testarea virtuală a unor tratamente, înainte ca acestea să fie aplicate efectiv pacientului real. Prin digital twins, medicina capătă un instrument revoluționar de predicție și prevenție, reducând riscurile și optimizând intervențiile.

Nu în ultimul rând, **calculul cuantic** promite să accelereze enorm procesarea datelor medicale complexe. Spre deosebire de calculatoarele clasice, cele cuantice pot analiza simultan multiple variabile și interacțiuni, ceea ce le face ideale pentru modelarea structurilor moleculare sau pentru descoperirea de medicamente. Deși încă aflată la început, această tehnologie are potențialul de a transforma cercetarea biomedicală și de a permite descoperirea rapidă de terapii inovatoare.

Astfel, viitorul informaticii medicale se conturează la intersecția dintre AI, medicina de precizie, digital twins și calculul cuantic, deschizând calea către o **medicină personalizată, predictivă și preventivă**, în care deciziile clinice sunt susținute de modele digitale complexe și simulări avansate. Pentru studenții la medicină, este esențial să înțeleagă că viitorul profesiei lor va fi profund marcat de colaborarea cu algoritmi inteligenți.

Întrebări pentru reflecție

1. Ce responsabilități etice are un medic atunci când folosește algoritmi AI pentru diagnostic?
2. Ar trebui pacienții să aibă control complet asupra propriilor date medicale digitale?
3. Care sunt avantajele și riscurile medicinei personalizate bazate pe AI?
4. Poate fi considerat AI un „coleg de echipă” pentru medic sau rămâne un simplu instrument?
5. Cum influențează AI relația medic–pacient?

De reținut

- Informatica medicală a evoluat de la primele baze de date la AI și IoMT.
- AI este un factor integrator al domeniilor informatice medicale, nu un înlocuitor.
- Aplicațiile clasice rămân fundamentale, dar sunt complet transformate de algoritmi și rețele digitale.
- Medicina pacientului digital pune individul în centru prin dispozitive conectate și auto-monitorizare.
- Provocările includ securitatea datelor, biasul algoritmic și redefinirea rolului medicului.
- Perspectivele vizează medicina de precizie, digital twins și calculul cuantic.

Capitolul 2 – Arhitectura sistemelor de calcul

2.1. Introducere – calculatorul ca instrument al medicinei digitale

Calculatorul electronic, în sensul său clasic, este o mașină capabilă să primească instrucțiuni și date (input), să le proceseze conform unor reguli logice prestabilite și să furnizeze rezultate (output). Definiția aceasta, aparent simplă, ascunde o complexitate remarcabilă, pentru că fiecare act de prelucrare implică o arhitectură hardware și software sofisticată.




Fig. 2.1. Componentele unui calculator personal: 1. Scanner, 2. CPU (microprocesor), 3. Memorie (RAM), 4. Plăci de extensie (placă grafică, etc.), 5. Sursă de alimentare, 6. Unitate optică (CD/DVD), 7. Stocare (hard disk sau SSD), 8. Placă de bază, 9. Boxe, 10. Monitor, 11. Sistem de operare, 12. Software de aplicații, 13. Tastatură, 14. Mouse, 15. Unitate de stocare externă, 16. Imprimantă. Sursă: Wikimedia Commons, CC-BY-SA

În medicină, calculatorul nu este doar un instrument de birou, ci nucleul oricărui sistem digital de sănătate. De la imagistica medicală de înaltă rezoluție, la monitorizarea pacienților în terapie intensivă și până la aplicațiile mobile care urmăresc starea de sănătate a unui individ, toate depind de calculatoare și de arhitectura lor.

În acest capitol vom analiza structura și evoluția sistemelor de calcul, cu accent pe procesoarele neuronale și pe calculatoarele cuantice, două dintre cele mai promițătoare direcții pentru viitorul informaticii medicale.

2.2. Hardware și software – concepte fundamentale

Orice sistem de calcul este alcătuit din două componente majore:


- hardware-ul – totalitatea dispozitivelor fizice, de la unitatea centrală de procesare (CPU) la memorie, plăci de rețea, monitoare sau senzori medicali;
- software-ul – programele care dau viață hardware-ului, permițându-i să execute instrucțiuni utile.

În practica medicală, această distincție devine foarte clară. Un ecograf modern, de exemplu, este alcătuit din sonde, procesor grafic, monitor și sistem de stocare (hardware), dar nu ar putea fi utilizat fără software-ul care interpretează undele ultrasonice, generează imagini și oferă funcții de măsurare automată.

Astfel, hardware-ul este corpul, iar software-ul este inteligența calculatorului. Împreună, ele fac posibilă informatica medicală modernă.

2.3. Arhitectura clasică a calculatoarelor

Arhitectura clasică a unui calculator se bazează pe modelul lui Von Neumann, formulat în anii 1940, dar încă prezent în majoritatea sistemelor actuale.



Ea include câteva componente esențiale:

- Unitatea centrală de prelucrare (CPU), compusă din:
 - *Unitatea de comandă și control* (UCC), responsabilă cu interpretarea instrucțiunilor și coordonarea activităților interne;
 - *Unitatea aritmetică și logică* (UAL), care efectuează operații matematice și logice.
- Memoria internă:
 - *RAM* (memoria de lucru) – stochează programele și datele active, dar este volatilă;
 - *ROM* – conține instrucțiuni fixe, precum cele de pornire a sistemului;
 - *cache* – memorie rapidă care accelerează comunicarea între CPU și RAM.
- Dispozitivele de stocare (memoria externă): hard-disk-urile clasice au fost înlocuite treptat de SSD-uri cu viteze mult superioare; în medicină, stocarea se face adesea și în cloud securizat, unde dosarele electronice pot fi accesate de la distanță.
- Unități de intrare și ieșire: tastatură, mouse, scanner, camere video, imprimante sau monitoare de înaltă rezoluție. În medicină, acestea includ și echipamente specializate precum scannerele RMN, aparatele de radiografie digitală, sau imprimantele 3D pentru proteze personalizate.

Acest model fundamental este prezent în orice dispozitiv – de la un simplu smartphone, până la un supercomputer medical utilizat pentru analiza datelor genomice.

2.4. Evoluția microprocesoarelor

Microprocesorul, „creierul” oricărui sistem de calcul, a cunoscut o evoluție spectaculoasă în ultimele decenii.

La început, procesoarele lucrau pe 8 sau 16 biți și aveau frecvențe de câțiva MHz. Astăzi, procesoarele moderne pot avea zeci de nuclee, fiecare capabil să ruleze miliarde de instrucțiuni pe secundă. Arhitectura pe 64 de biți este standard, iar frecvențele depășesc 3 GHz.

Un aspect crucial este diversificarea arhitecturilor:

- procesoarele x86 (Intel, AMD) domină calculatoarele personale și serverele;
- procesoarele ARM au devenit esențiale pentru dispozitivele mobile și, implicit, pentru sănătatea mobilă (*mHealth*), deoarece oferă un raport excelent între performanță și consumul redus de energie.

🕒 Un exemplu medical concret: un smartwatch echipat cu procesor ARM poate monitoriza ritmul cardiac și saturația în oxigen, trimițând datele în timp real către un server medical.

Un aspect esențial al evoluției microprocesoarelor este creșterea exponențială a puterii de calcul, descrisă inițial de „Legea lui Moore”. Aceasta observație arată că numărul de tranzistori de pe un cip se dublează aproximativ la fiecare doi ani, ceea ce duce la creșterea performanței și la reducerea costurilor. Deși în prezent legea lui Moore nu mai este respectată strict, tendința generală de creștere accelerată a puterii de procesare continuă, datorită arhitecturilor multicore, optimizărilor de energie și integrării unităților specializate (GPU, NPU). În medicină, această creștere exponențială s-a tradus prin trecerea de la simulări simple de imagini la analize genomice la scară populațională și la algoritmi de inteligență artificială capabili să prelucreză miliarde de date clinice în timp real.

Caz clinic

🕒 Într-un spital de urgență, un pacient cu suspiciune de accident vascular cerebral este evaluat printr-un algoritm de recunoaștere a imaginilor de tomografie cerebrală. Acest algoritm rulează pe o unitate GPU și NPU, reușind să identifice rapid semne subtile de ischemie, ceea ce permite medicilor să administreze tratamentul trombolitic în primele minute, crescând șansele de recuperare.

2.5. Procesoare neuronale (NPU)

O inovație recentă este apariția unităților de procesare neuronală (NPU), procesoare specializate în sarcini de inteligență artificială.

Spre deosebire de un CPU clasic, optimizat pentru calcule generale, sau de un GPU (procesor grafic) destinat prelucrării masive de date vizuale, NPU este proiectat să execute rapid operații specifice rețelelor neuronale artificiale: recunoaștere de imagini, analiză de semnale complexe, procesare a limbajului natural.

În medicină, rolul NPUs este crucial. De exemplu, un smartphone echipat cu NPU poate analiza imagini dermatologice direct pe dispozitiv, fără a trimite datele către un server. Aceasta aduce două avantaje majore: viteză în diagnostic și protecția confidențialității datelor pacientului.

Pe viitor, NPUs vor fi integrate în toate echipamentele medicale portabile, făcând posibilă analiza inteligentă „la margine” (edge computing), fără dependență de cloud.

Tabelul 2.1. CPU vs GPU vs NPU

Caracteristică	CPU (Unitate centrală)	GPU (Unitate grafică)	NPU (Procesor neuronal)
Rol principal	Generalist: execută diverse sarcini logice și aritmetice	Prelucrare masivă de date vizuale	Optimizat pentru inteligență artificială
Tip de sarcini	Operații diverse, gestionare sisteme și aplicații	Randare grafică, calcule masive în paralel	Rețele neuronale, machine learning, NLP
Paralelism	Redus	Foarte ridicat (mii de nuclee)	Optimizat pentru AI, paralelism specializat
Viteză pentru AI	Scăzută	Medie	Foarte ridicată
Aplicații medicale	Sisteme EHR, aplicații clinice standard	Imagistică medicală, simulări 3D	Recunoaștere imagini, analiză biosemnale, AI pe mobil

2.6. Calculatoarele cuantice – principii și provocări

Un calculator clasic procesează informația în biți, care pot avea doar două valori: 0 sau 1. Toate calculele, indiferent de complexitate, se reduc la combinații de astfel de stări binare.

În schimb, un calculator cuantic folosește unități fundamentale de informație numite qubiți. Spre deosebire de biții clasici, un qubit poate fi simultan într-o stare de 0 și 1, fenomen numit suprapunere cuantică (Fig. 2.2 stg.). Această proprietate face posibilă explorarea, în paralel, a unui număr uriaș de combinații.




Fig. 2.2. (stg.) Qubiții pot fi într-o suprapunere a tuturor stărilor permise clasic
(dr.) Schița unui model de calculator cuantic, unde se pot observa circuitele de răcire

O altă caracteristică fascinantă este entanglement-ul (inseparabilitatea cuantică). Doi sau mai mulți qubiți pot deveni interconectați într-un mod profund: modificarea stării unuia influențează instantaneu starea celuilalt, chiar dacă se află la distanță. Într-un sistem cu mulți qubiți sincronizați, calculele pot fi realizate într-o manieră colaborativă, cu o putere de procesare incomparabil mai mare decât în logica binară clasică.

Calculul cuantic are potențialul de a aduce o schimbare fundamentală în medicină, deschizând perspective ce depășesc cu mult capacitatea sistemelor clasice de calcul. Una dintre cele mai promițătoare aplicații este descoperirea de medicamente. Prin posibilitatea de a simula cu precizie interacțiunile la nivel molecular, calculatoarele cuantice ar putea accelera identificarea unor

molecule cu potențial terapeutic, reducând costurile și timpul necesar cercetării. În domeniul modelării proteinelor, capacitatea de a analiza rapid plieri și structuri complexe ar putea oferi o mai bună înțelegere a bolilor genetice sau neurodegenerative.

Tabelul 2.2. Calculator clasic vs Calculator cuantic

Caracteristică	Calculator clasic	Calculator cuantic
Unitatea de informație	Bit (0 sau 1)	Qubit (0 și 1 simultan)
Principiu de funcționare	Logică binară secvențială	Suprapunere și entanglement
Capacitate de calcul	Limitată la combinații liniare	Exponențial mai mare (paralelism cuantic)
Stabilitate	Foarte stabil	Instabil (decoerență rapidă)
Aplicații medicale actuale	EHR, imagistică, sisteme clinice	Încă inexistente clinic
Aplicații medicale viitoare	Performanță standard	Genomică, medicină personalizată, descoperire de medicamente

Un alt domeniu unde calculul cuantic ar putea juca un rol major este analiza genomică. Procesarea și compararea unor volume uriașe de date genetice, care pe sisteme clasice durează săptămâni sau luni, ar putea fi realizată mult mai rapid, sprijinind medicina personalizată. Tot aici se înscrie și integrarea datelor multi-omice (genomică, proteomică, metabolomică, lipidomică), care ar permite obținerea unui tablou complet al pacientului și dezvoltarea de terapii adaptate fiecărui profil biologic. În viitor, un algoritm cuantic ar putea analiza în câteva minute întreg genomul unui pacient oncologic și ar putea sugera terapia personalizată optimă, reducând astfel luni de investigații

În imagistica medicală, calculatoarele cuantice ar putea facilita reconstrucția de imagini de înaltă rezoluție și procesarea unor seturi masive de date imagistice, crescând acuratețea diagnosticului. Mai mult, în optimizarea fluxurilor medicale și a logisticii spitalicești, algoritmi cuantici ar putea ajuta la gestionarea resurselor și planificarea intervențiilor într-un mod mult mai eficient decât sistemele tradiționale.

Totuși, aceste promisiuni sunt însoțite de limitări semnificative. Calculatoarele cuantice sunt foarte fragile. Ele funcționează pe baza unor particule aflate într-o stare specială, care se poate pierde foarte ușor din cauza factorilor externi. Acest fenomen, numit decoerență cuantică, face ca rezultatele să devină instabile. Pentru a le proteja, aceste calculatoare trebuie păstrate în condiții extreme: la temperaturi aproape de zero absolut și într-un mediu complet izolat de zgomotul și vibrațiile din jur (fig. 2.2. dr.). Toate acestea le fac foarte costisitoare și greu de utilizat în afara unor laboratoare specializate.

De asemenea, în prezent, numărul de qubiți disponibili este limitat, ceea ce restrânge capacitatea de a rula aplicații complexe la scară reală. Sistemele actuale comerciale (IBM, Google, D-Wave) operează cu zeci sau câteva sute de qubiți, insuficient pentru aplicații medicale de scară largă. Există și o lipsă de algoritmi cuantici maturi dedicați problemelor medicale, majoritatea fiind încă în fază de experiment. Pe lângă aspectele tehnice, costurile de dezvoltare și întreținere sunt uriașe, ceea ce face ca accesul la această tehnologie să fie rezervat doar câtorva centre de cercetare de elită.

Astfel, calculul cuantic în medicină se află într-o etapă de mare promisiune, dar și de mari constrângeri. El nu va înlocui calculatoarele clasice, ci le va completa, fiind rezervat în viitorul apropiat problemelor de o complexitate extremă. Progresul în dezvoltarea hardware-ului, corecția erorilor cuantice și elaborarea de algoritmi specifici domeniului biomedical vor fi pașii necesari pentru ca aceste aplicații să treacă din laborator în practica clinică.

2.7. Software și sisteme de operare

Dacă hardware-ul este corpul calculatorului, software-ul este mintea sa. Sistemele de operare coordonează resursele hardware și permit aplicațiilor să funcționeze.

Sistemul de operare are un rol central în funcționarea oricărui calculator. Atunci când sistemul este pornit, nucleul sistemului de operare este încărcat automat în memoria operativă. Din acel moment, el acționează ca un veritabil „dirijor”, care controlează accesul la toate resursele calculatorului și la echipamentele periferice, de la tastatură și monitor până la imprimantă sau dispozitive externe. Totodată, sistemul de operare supraveghează execuția

tuturor celorlalte programe, asigurând că fiecare primește resursele necesare și că procesele nu intră în conflict.

În practica medicală se folosesc o varietate de sisteme de operare:

- Windows și Linux – pentru servere și aplicații clinice complexe;
- Android și iOS – pentru aplicații mobile de sănătate, folosite zilnic de milioane de pacienți și medici;
- sisteme integrate – prezente în echipamentele medicale (RMN, ecografe, ventilatoare).

Un exemplu relevant îl constituie platformele de dosar electronic al pacientului (EHR), care rulează pe servere Linux securizate și pot fi accesate de pe tablete iOS sau Android de către medici, în timp real.

Un alt rol esențial al sistemului de operare este modul în care organizează informația. În primele sisteme, precum MS-DOS, datele erau structurate în fișiere care erau grupate în dosare (foldere). Această structură era ierarhică: fiecare fișier avea un nume și o extensie care indica tipul său (de exemplu, .txt pentru text sau .exe pentru programe executabile). Limitările erau destul de stricte: numele fișierului nu putea depăși 8 caractere, extensia era obligatoriu de 3 litere, iar organizarea era mai puțin flexibilă.

Odată cu apariția Windows, sistemul de operare a adus o interfață grafică și o organizare mai prietenoasă a datelor. Utilizatorii au putut să creeze foldere în care să grupeze fișiere, să folosească nume mai lungi și să vizualizeze conținutul pe ecran într-un mod intuitiv, cu ajutorul pictogramelor. În plus, Windows a introdus funcții suplimentare, precum asocierea automată a tipurilor de fișiere cu anumite aplicații, posibilitatea de a căuta fișiere rapid sau de a le organiza după criterii precum dată, mărime sau tip.

Astfel, ceea ce în MS-DOS necesita cunoștințe de comenzi text, în Windows a devenit accesibil oricărui utilizator prin câteva click-uri. Într-un laborator, rezultatele analizelor biochimice erau inițial salvate în fișiere simple .txt; în prezent, ele sunt integrate în baze de date complexe, accesibile prin interfețe grafice intuitive. Pentru medicină, această evoluție a fost importantă deoarece a făcut mult mai ușoară gestionarea colecțiilor de date, a imaginilor medicale și a documentelor clinice, reducând barierele tehnice și crescând eficiența

lucrului cu informația digitală, facilitând tranziția de la evidența pe hârtie la evidența computerizată a datelor medicale.

2.8 Cloud computing în medicina digitală

Cloud computing reprezintă o etapă majoră în evoluția arhitecturii informatice, prin care serviciile informatice – precum stocarea, procesarea, bazele de date, rețelele sau aplicațiile software – nu mai sunt gestionate local, ci sunt furnizate prin internet. Cu alte cuvinte, în loc ca fiecare spital sau clinică să dețină servere proprii, infrastructura este partajată și accesibilă la distanță, ceea ce reduce costurile și crește flexibilitatea.

Există mai multe tipuri de servicii Cloud, care se diferențiază prin nivelul de control și responsabilitate:

- IaaS (Infrastructure as a Service): furnizează infrastructură virtuală (servere, spațiu de stocare, rețele), permițând spitalelor sau laboratoarelor să aibă acces la resurse scalabile, fără investiții în hardware propriu.
- PaaS (Platform as a Service): oferă platforme de dezvoltare și rulare a aplicațiilor medicale fără a gestiona direct serverele sau sistemele de bază. Acest model este frecvent folosit pentru aplicații de cercetare sau pentru dezvoltarea rapidă de soluții digitale.
- SaaS (Software as a Service): pune la dispoziție aplicații complete prin cloud, accesibile de oriunde. În medicină, acest tip de serviciu stă la baza portalurilor electronice pentru pacienți sau a soluțiilor de telemedicină.

În practică, cloud computing este deja prezent în numeroase domenii medicale. De exemplu, sistemele PACS moderne (Picture Archiving and Communication Systems) permit stocarea și accesarea imaginilor medicale în cloud, astfel încât radiologii să poată consulta cazuri de oriunde. Un pacient diabetic își înregistrează zilnic glicemia într-o aplicație mobilă; datele sunt stocate în cloud și medicul le poate consulta la distanță pentru a ajusta tratamentul. Tot prin cloud devine posibilă integrarea datelor clinice provenite din spitale diferite într-o singură bază comună, accesibilă pentru cercetare sau pentru urmărirea pacienților cronici. Mai mult, algoritmi de inteligență artificială sunt adesea rulați pe servere cloud, acolo unde există resurse de calcul suficiente pentru analiza masivă a datelor genomice sau imagistice.

Această abordare nu este lipsită de provocări. Principala preocupare este securitatea și confidențialitatea datelor medicale, extrem de sensibile și reglementate strict. În plus, utilizarea cloud-ului depinde de existența unei conexiuni stabile la internet, iar costurile pot deveni considerabile atunci când volumele de date sunt foarte mari.

Cu toate acestea, cloud computing rămâne o componentă esențială a medicinei digitale moderne, oferind infrastructura necesară pentru o îngrijire mai rapidă, mai eficientă și mai bine conectată.

2.9. Arhitectura calculatoarelor în era AI și a medicinei digitale

Arhitectura sistemelor de calcul a evoluat enorm: de la mașinile simple capabile doar să execute operații aritmetice de bază, la procesoare neuronale și computere cuantice cu potențial revoluționar.

În medicină, aceste progrese nu sunt doar detalii tehnice, ci factori care schimbă profund modul în care pacienții sunt diagnosticați, tratați și monitorizați.

- Procesoarele multicore și GPU-urile accelerează analiza imaginilor medicale.
- NPUs aduc inteligența artificială la îndemâna fiecărui pacient, prin dispozitive mobile.
- Calculatoarele cuantice promit o revoluție în cercetarea medicală și în medicina personalizată.

Un element definitoriu al arhitecturii moderne este integrarea **asistenților bazați pe inteligență artificială** direct în aplicațiile utilizate zilnic. Spre exemplu, instrumente precum **Microsoft Copilot** sunt deja capabile să ofere sugestii inteligente în timp real, să genereze rapoarte sau să ajute la interpretarea datelor complexe. În medicină, astfel de funcționalități se traduc prin integrarea AI în sistemele de dosar electronic al pacientului (EHR), unde algoritmiile pot sugera investigații suplimentare, pot semnală interacțiuni medicamentoase periculoase sau pot genera rezumate automate ale istoricului medical.

Totodată, apar și **asistenți conversaționali specializați pe domeniul medical**, care pot răspunde la întrebări despre protocoale clinice, pot ghida

procesul de diagnostic diferențial sau pot oferi suport pacienților prin aplicații mobile. Acești asistenți AI devin posibile extensii ale arhitecturii informatice medicale, funcționând ca interfață între medic, pacient și volumul imens de date disponibile.

Astfel, arhitectura calculatoarelor în era AI nu se limitează doar la procesare mai rapidă sau la noi tipuri de procesoare, ci include integrarea directă a unor **mecanisme inteligente de sprijin decizional**, care transformă modul în care sunt utilizate resursele digitale în medicină.

Pentru studentul la medicină, cunoașterea arhitecturii calculatoarelor nu este doar un exercițiu tehnic, ci o cheie pentru înțelegerea viitorului medicinei. În epoca digitală, medicul și calculatorul – clasic, neuronal sau cuantic – formează o echipă inseparabilă.

De reținut

1. Fundamentele arhitecturii calculatoarelor

- Orice calculator procesează date prin interacțiunea dintre hardware (componente fizice) și software (programe).
- Arhitectura clasică, descrisă de modelul von Neumann, include CPU, memorie, unități de stocare și periferice.

2. Procesoare specializate pentru medicină digitală

- GPU-urile sunt optimizate pentru calcule paralele masive, utile în imagistică medicală și simulări 3D.
- NPU-urile accelerează aplicațiile de inteligență artificială, sprijinind diagnosticul asistat de AI și analiza biosemnalelor.

3. Calculul cuantic

- Qubiții pot exista simultan în stări de 0 și 1 (suprapunere) și pot fi interconectați prin entanglement.
- Limitările actuale: instabilitatea qubiților, numărul redus de unități, necesitatea corecției de erori și costurile mari.

4. Cloud computing în medicina digitală

- Permite stocarea și procesarea datelor medicale prin internet, prin servicii de tip IaaS, PaaS și SaaS.
- Avantaje: accesibilitate și scalabilitate; provocări: securitatea datelor și dependența de internet.

Capitolul 3 – Date, informații și cunoștințe medicale

3.1. Teoria informației

În practica medicală modernă, informația este la fel de importantă precum medicamentele sau instrumentele de diagnostic. Medicul ia decizii nu doar pe baza experienței proprii, ci și prin interpretarea unui flux continuu de date furnizate de pacient, de investigații paraclinice sau de sisteme informatice. Pentru a înțelege modul în care aceste date pot fi colectate, transmise și interpretate, este necesară o scurtă introducere în teoria informației, pornind de la un concept fundamental: **probabilitatea**.

Variabile deterministe și aleatoare.

Orice act de măsurare a unor parametri biologici produce variabile. Unele sunt deterministe, adică au valori bine definite și repetabile (de exemplu, grupa sanguină a unui pacient). Altele sunt aleatoare (stochastice), cum ar fi valorile tensiunii arteriale, care pot varia de la o măsurare la alta. Teoria probabilităților permite cuantificarea acestor variații și înțelegerea fenomenelor medicale în termeni de distribuții statistice, nu doar de valori fixe.

Experiment și eveniment.

În limbajul teoriei informației, un experiment este procesul prin care un sistem evoluează către o stare finală – un rezultat, iar evenimentul este chiar acel rezultat ($X_1...X_k$). În medicină, experimentul poate fi o analiză de laborator, iar evenimentul este valoarea obținută la determinarea glicemiei. Fiecare eveniment are asociată o frecvență de apariție (frecvența absolută - n_i : $n_1...n_k$), care raportată la numărul de experimente (N) indică frecvența relativă a acelui eveniment (n_i / N). Dacă repetăm un experiment de un număr mare de ori ($N \rightarrow \infty$), frecvența relativă tinde spre o valoare bine definită, care reprezintă probabilitatea (p_i) de apariție a acelui eveniment.

$$p_i = \lim_{N \rightarrow \infty} \frac{n_i}{N} \quad (3.1)$$

$$\text{Simplificat, putem scrie} \quad P(A) = n_A / N \quad (3.2)$$

unde n_A = numărul de cazuri favorabile și N = numărul total de cazuri posibile.

Exemplu numeric. Dacă din 1000 de pacienți testați pentru gripă, 300 sunt pozitivi, probabilitatea ca un pacient ales la întâmplare să fie infectat este $P=300/1000=0,3$, adică 30%.

Ansamblul tuturor evenimentelor posibile formează „câmpul de evenimente”, iar ansamblul tuturor probabilităților asociate evenimentelor posibile în urma desfășurării unui experiment formează un „câmp de probabilități”.

$$\begin{vmatrix} X_1 & X_2 & \dots & X_k \\ n_1 & n_2 & \dots & n_k \end{vmatrix}$$

Câmp de evenimente

$$\begin{vmatrix} X_1 & X_2 & \dots & X_k \\ p_1 & p_2 & \dots & p_k \end{vmatrix}$$

Câmp de probabilități

Probabilitatea exprimă șansa ca un anumit eveniment să aibă loc. Ea variază între 0 (eveniment imposibil) și 1 (eveniment sigur). De exemplu, probabilitatea ca un pacient să aibă grupa sanguină „AB” într-o populație este de aproximativ 4%. Evenimentele pot fi:

- **sigure** (probabilitate = 1), ex.: un pacient va avea mereu o anumită grupă sanguină;
- **imposibile** (probabilitate = 0), ex.: un rezultat de laborator cu valoare negativă pentru o concentrație;
- **echiprobabile**, atunci când au aceeași șansă de apariție (ex.: la aruncarea unui zar corect, fiecare față are șansa de 1/6).



Acest cadru probabilistic este esențial pentru medicină, unde rareori ne confruntăm cu certitudini absolute. Majoritatea diagnosticelor se formulează pe baza unor probabilități, nu a unor determinări exacte.

 *Exemplu clinic.* Dacă o mutație genetică precum BRCA1 este asociată cu un risc de 80% de cancer de sân, aceasta înseamnă că, în populația femeilor purtătoare, aproximativ 8 din 10 vor dezvolta cancer de sân pe parcursul vieții. În termeni probabilistici, probabilitatea cumulativă este de 0,8. Totuși, acest risc nu se aplică predictiv pentru o persoană individuală – unele purtătoare nu vor dezvolta niciodată boala, iar altele o pot dezvolta mai devreme sau mai târziu, în funcție de alți factori genetici și de mediu.

Noțiunea de informație.

Informația este un concept abstract, dar fundamental, care exprimă procesul de reducere a incertitudinii asupra unui eveniment. Ea nu este nici materie, nici energie, ci o categorie de natură logică abstractă, dependentă de existența unui receptor capabil să o interpreteze.

Proprietatea fundamentală a informației este aceea de a elimina o nedeterminare. De exemplu, rezultatul unui test de sarcină răspunde întrebării „este pacienta gravidă sau nu?”, transformând o situație de incertitudine într-una de claritate.

Valoarea utilă a informației. Informația nu are aceeași valoare pentru toți receptorii; ea depinde de context și de scopul pentru care este folosită. În medicină, aceeași valoare numerică poate fi interpretată diferit: o glicemie de 126 mg/dl este semnificativă pentru un diabetolog (confirmă diagnosticul de diabet), dar poate trece neobservată într-un alt context clinic. Un ceas inteligent poate înregistra sute de valori ale pulsului într-o zi, dar doar episoadele de tahicardie sau aritmie au valoare clinică reală. Astfel, utilitatea informației este legată de relevanța sa pentru decizia medicală și pentru nevoile receptorului.

Informație versus adevăr. Informația nu se suprapune întotdeauna cu adevărul. Ea reflectă o reducere a incertitudinii, dar nu garantează corectitudinea absolută. Un rezultat de laborator poate oferi informație (ex.: „valoarea hemoglobinei este 10 g/dl”), dar aceasta nu înseamnă automat că este adevărat – poate fi eronat din cauza unei probe contaminate sau a unei erori tehnice. De aceea, informația trebuie validată prin repetare, prin corelare cu alte date și prin expertiza clinică a medicului.

Această distincție este crucială în practica medicală, unde deciziile nu pot fi luate pe baza unei singure surse, ci necesită coroborarea mai multor informații și verificarea lor în context.

 *Exemplu clinic.* O radiografie pulmonară poate arăta o opacitate suspectă. Această imagine furnizează informație, dar valoarea ei utilă depinde de context (istoric medical, simptome, analize suplimentare). Mai mult, informația nu este sinonimă cu adevărul: leziunea poate fi o tumoră, dar la fel de bine poate fi o cicatrice fibrotică sau o imagine fals pozitivă. Doar

integrarea acestei informații cu alte date și cu raționamentul clinic al medicului o transformă în informație validă și utilă.

Cantitatea de informație.

Claude Shannon a formalizat această noțiune în 1948, introducând unitatea de măsură „bit” (binary digit). Un bit reprezintă cantitatea de informație necesară pentru a elimina o nedeterminare de $\frac{1}{2}$ (de tip „da/nu”).

$$I_i = \log_2 \frac{1}{p_i} = -\log_2 p_i \quad (3.3)$$

Unitățile multiple – byte (sau octet), kilobyte (kilo-octet), megabyte, gigabyte – descriu volumele tot mai mari de date medicale cu care lucrăm astăzi: de la câțiva kilo-octeți pentru un rezultat de laborator, la giga- sau tera-octeți pentru imagistica de înaltă rezoluție sau genomică.

Kilo-octet (1 KB) = 2^{10} bytes = 1024 bytes

Mega-octet(1 MB) = 2^{10} KB = 1024 KB

Giga-octet(1 GB) = 2^{10} MB = 1024 MB

Terra-octet(1 TB) = 2^{10} GB = 1024 GB




Fig. 3.1. Multiplii Byte-ului și aplicații medicale reprezentative

Redundanța informației

Nu toată informația transmisă într-un sistem este „nouă”. O parte din ea se repetă, confirmând mesajul inițial sau asigurând rezistența la erori. Această repetiție poartă numele de **redundanță**.

Redundanța absolută reprezintă cantitatea efectivă de informație repetată într-un mesaj.

 *Exemplu clinic.* un raport de laborator care listează de mai multe ori date de identificare ale pacientului (nume, CNP) – acestea nu aduc informații noi, dar asigură corectitudinea documentului.

Redundanța relativă exprimă proporția de informație repetată în raport cu întreaga cantitate de informație din mesaj.

 *Exemplu clinic.* dacă într-o scrisoare medicală de o pagină, 30% din conținut constă în repetiții (date administrative, diagnostice menționate de mai multe ori), atunci redundanța relativă este de 30%.

În medicină, redundanța nu este o pierdere, ci o **măsură de siguranță**: datele repetate reduc șansele de interpretare greșită. Un exemplu concret este monitorizarea tensiunii arteriale – aceeași valoare, confirmată de mai multe măsurători succesive, are mai multă credibilitate decât o singură înregistrare izolată.

Transmiterea informației.

Informația există doar atunci când există un **receptor** capabil să o perceapă și să o interpreteze. O persoană are, de exemplu, un anumit ritm al contracțiilor inimii, dar acest ritm devine **informație** doar în momentul în care este măsurat – prin palparea pulsului, printr-un tensiometru sau printr-un senzor electronic.




Fig. 3.2. Componentele unui sistem de comunicație

De cele mai multe ori, receptorul nu se află în același loc cu sursa, ci la o **distanță în spațiu**. Din acest motiv, între sursă și receptor este necesar un **canal de comunicație**. Canalul poate fi reprezentat de fibre nervoase (în corpul uman), aerul prin care se transmit unde sonore (în fonocardiografie), cabluri electrice, unde electromagnetice sau rețele informatice (în telemedicină).

Informația transmisă prin canal se numește **mesaj**, iar suportul său fizic este **semnalul**. În medicină, semnalul poate fi electric (ECG), acustic (ecografie), electromagnetic (radiografie) sau digital (un fișier transmis prin internet). Toate formele posibile ale unui semnal alcătuiesc un **alfabet**.

Transmiterea nu este niciodată perfectă. Canalul poate introduce **zgomote** – interferențe, erori de măsurare, artefacte sau pierderi de semnal – care alterează mesajul. Pentru a compensa aceste perturbări, sistemele de comunicație folosesc **redundanța**, adică repetarea parțială sau completă a informației.

- În monitorizarea continuă a ritmului cardiac, același tipar ECG apare de mai multe ori, ceea ce permite medicului să distingă o aritmie reală de un artefact generat de zgomot.
- În documentele medicale, datele esențiale (nume pacient, diagnostic principal) apar în mod redundant, pentru a preveni erorile de identificare.

Astfel, deși redundanța poate părea un „supraplin” de informație, în practică ea reprezintă un mecanism necesar pentru asigurarea **fiabilității și siguranței** în transmiterea datelor medicale.

Complexitatea transmisiei crește atunci când sunt necesari traductori care schimbă natura fizică a semnalului (ex. senzori care transformă un semnal fiziologic într-un semnal digital), modemuri (pentru modulare/demodulare) sau algoritmi de codificare care asigură traducerea din alfabetul emițătorului în cel al receptorului.




Fig. 3.3. Componentele unui sistem de comunicație complex

Capacitatea canalului de comunicație se exprimă în biți pe secundă (bps, baud) și determină viteza cu care un semnal ECG, o imagine CT sau un fișier genomic poate fi transmis către medic. O consultație video necesită câțiva MB, dar o serie RMN poate depăși sute de MB, iar un fișier genomic – mai mulți GB.

 *Exemplu clinic.* Un pacient purtător de monitor Holter generează, în 24 de ore, milioane de înregistrări ale ritmului cardiac. Fiecare complex QRS este un eveniment. Semnalele ECG, transmise printr-un canal de comunicație, pot fi distorsionate de zgomot. Redundanța înregistrărilor succesive face însă posibilă identificarea corectă a unor aritmii, chiar și atunci când o parte dintre semnale sunt perturbate. Înregistrarea completă devine o sursă de date, care, transmisă printr-un canal de comunicație, se transformă în informație utilă abia când medicul cardiolog sau un algoritm AI o interpretează și identifică tipare clinice (de exemplu, fibrilație atrială).

Transferul informației în sistemele biologice

Conceptul de transmitere a informației nu se aplică doar în tehnologie și în comunicarea medic–pacient, ci este prezent și în biologia organismelor vii. Viața însăși poate fi privită ca un proces continuu de stocare, transfer și prelucrare a informației.

Codul genetic

Un prim exemplu fundamental îl constituie **ADN-ul**, molecula care poartă informația genetică. Alfabetul său este format din patru baze azotate (A, T, C, G – în ARN, T este înlocuit de U).

- Informația este stocată sub forma secvenței acestor baze.
- **Replicarea ADN-ului** asigură transferul fidel al informației la fiecare diviziune celulară.

- La nivel funcțional, informația genetică este organizată în **codoni** (grupuri de trei baze), fiecare codon specificând un anumit aminoacid în procesul de sinteză proteică. Astfel, un șir de codoni devine un „mesaj” care se traduce într-un lanț de aminoacizi – proteina – responsabilă de funcțiile celulare.

Codificarea în sistemul nervos

Sistemul nervos utilizează alte mecanisme de codificare a informației:

- **Pe axoni**, informația este transmisă prin **frecvența impulsurilor electrice** (potențiale de acțiune). Cu cât stimulul este mai intens, cu atât descărcările sunt mai frecvente.
- **La nivelul dendritelor și al sinapselor**, informația este reprezentată prin **amplitudinea și intensitatea** semnalelor biochimice (potențiale postsinaptice, concentrația mediatorilor chimici). Această dublă modalitate – frecvență și amplitudine – permite o codificare complexă și adaptată la diferitele funcții ale sistemului nervos.



Fig. 3.3. Photo by [Stockcake](#)

Informația externă și internă

- **Informația externă** este captată de organele de simț (ochi, urechi, piele, limbă, nas) și adusă către creier prin căi senzoriale specializate. Aceasta reflectă interacțiunea organismului cu mediul înconjurător.

- **Informația internă** este colectată de **interoreceptori** – receptori situați în organele interne și în vasele de sânge. Ei transmit date despre presiunea arterială, pH, nivelul oxigenului, concentrația de glucoză și alți parametri vitali.

Astfel, la nivel biologic, transferul informației se realizează prin mecanisme diferite, dar toate respectă aceleași principii generale: existența unei **surse**, a unui **canal de comunicație**, a unui **cod de transmitere** și a unui **receptor** capabil să interpreteze mesajul.

Ciclul elementar al activității medicale

Transmiterea informației nu are loc doar în sisteme tehnice, ci și în practica medicală de zi cu zi. Actul medical însuși poate fi privit ca un caz particular de **proces de comunicare**, în care informația circulă între pacient și medic.

1. **Sursa** este pacientul, care prezintă anumite date – simptome subiective (anamneza) sau semne obiective (rezultatele examenului clinic, analize de laborator, investigații imagistice).
2. **Canalul de comunicație** este reprezentat de interacțiunea clinică și de mijloacele tehnice care transmit datele de la pacient la medic (examenul fizic, aparatura de monitorizare, fișele medicale electronice).
3. **Receptorul** este medicul, care interpretează datele și le transformă în **informații**. Pe baza **cunoștințelor medicale** acumulate, aceste informații conduc la formularea unui **diagnostic**.
4. Odată stabilit diagnosticul, medicul transmite pacientului un **plan terapeutic** – care poate fi văzut ca un mesaj invers, de la medic către pacient.
5. Ca urmare a aplicării tratamentului, pacientul ajunge într-o **nouă stare** (vindecat, ameliorat sau, în unele cazuri, agravat). Această stare devine punctul de plecare pentru un **nou ciclu informațional**, deoarece medicul va colecta din nou date pentru a evalua efectele intervenției.

Astfel, ciclul elementar al activității medicale este un **proces recurent de transmitere și transformare a informației**: de la pacient → către medic →

înapoi către pacient. Informatica medicală are rolul de a sprijini fiecare verigă a acestui ciclu, prin instrumente care facilitează colectarea datelor, integrarea informațiilor și sprijinirea deciziei clinice.




Fig. 3.3. Ciclul elementar al informației medicale

Exemplu clinic. Un pacient se prezintă cu febră și tuse:

- **Date:** anamneza relevă tuse productivă, examenul clinic arată raluri pulmonare, analizele indică leucocitoză, iar radiografia confirmă un infiltrat.
- **Informații:** asocierea acestor date sugerează o pneumonie.
- **Cunoștințe:** pe baza ghidurilor clinice, medicul formulează diagnosticul de pneumonie bacteriană și inițiază antibiotic.
- **Rezultat:** după câteva zile de tratament, pacientul se ameliorează, ceea ce încheie un ciclu și deschide posibilitatea de monitorizare ulterioară.

3.2. Date, informații și cunoștințe în medicină

După ce am prezentat bazele teoriei informației și modul în care aceasta poate fi cuantificată și transmisă, este momentul să analizăm mai detaliat cum se manifestă aceste concepte în medicină, sub forma datelor, informațiilor și cunoștințelor.

În medicină, fiecare etapă a procesului de îngrijire pornește de la date. Acestea sunt transformate, prin interpretare și integrare, în informații și apoi în cunoștințe care sprijină deciziile clinice. Diferențierea acestor concepte este fundamentală pentru înțelegerea informaticii medicale.




Fig. 3.4. Cele trei forme ale informației: date, informații, cunoștințe

Datele sunt reprezentări formalizate sau fapte (“instanțe”), adecvate prelucrărilor umane sau automate. Ele sunt reprezentate de valori brute, rezultate ale unor observații sau măsurători, fără interpretare.

Exemple medicale:

- termometrul indică „38,2°C”;
- Glicemie = „130 mg/dl”;
- Semnal electric brut pe ECG;
- Imagine radiologică în format DICOM;
- Numărul de pași înregistrați de un ceas inteligent.

Datele pot fi:

- **calitative** – anamneza („dispnee la efort”);
- **numerice** – valori de laborator ($\text{Na}^+ = 142 \text{ mmol/L}$);
- **grafice** – curbe ECG, EEG;
- **sunete** – fonocardiograma;
- **imagini statice** – radiografie, CT;
- **imagini dinamice** – film ecografic.

Informația reprezintă date interpretate într-un context, care reduc incertitudinea.

Exemple medicale:

- 38,2°C → „pacientul are febră”;
- glicemie 130 mg/dl → „hiperglicemie”;
- curba ECG → „ritm sinus al cu extrasistole”.

Astfel, informația presupune procesarea datelor prin reguli sau cunoștințe medicale de bază.

Cunoștințele reprezintă ansamblul de informații - cu caracter general, contextual - precum și reguli, valori, experiențe. Ele permit luarea unor decizii în funcție de informațiile existente.

Exemple medicale:

- „Febră și tusea productivă, corelate cu imaginea radiologică, indică pneumonie bacteriană.”
- „Hiperglicemia persistentă, asociată cu poliurie și polidipsie, confirmă diagnosticul de diabet zaharat tip 2.”
- „Extrasistolele ventriculare frecvente la un pacient cu infarct miocardic anterior cresc riscul de aritmii severe.”

Cunoștințele medicale nu sunt doar acumulări individuale, ci și colective: ele se regăsesc în ghiduri clinice, baze de date științifice și, tot mai des, în algoritmi de inteligență artificială.

Tabelul 3.1. Date-Informații-Cunoștințe

Nivel	Definiție	Exemplu medical	Întrebare la care răspunde
Date	Măsurători brute, fără interpretare	„Glicemie = 130 mg/dl”	<i>Ce s-a măsurat?</i>
Informații	Date interpretate, cu semnificație	„Pacientul are hiperglicemie”	<i>Ce înseamnă valoarea?</i>
Cunoștințe	Ansamblu integrat de informații și reguli	„Hiperglicemia persistentă confirmă diabet zaharat tip 2”	<i>Ce concluzie putem trage?</i>

Diferențierea dintre **date**, **informații** și **cunoștințe** poate fi extinsă prin introducerea unui nivel superior: **înțelepciunea (wisdom)**. Împreună, acestea

formează așa-numita **ierarhie DIKW** (Data – Information – Knowledge – Wisdom).

Înțelepciune (Wisdom) – capacitatea de a folosi cunoștințele în mod etic, responsabil și orientat spre binele pacientului. Exemple: alegerea unui antibiotic nu doar pe baza ghidului, ci și a particularităților pacientului (alergii, comorbidități, resurse disponibile).

- *Întrebarea la care răspund:* „Care este cea mai bună decizie, pentru acest pacient, în acest context?”

Astfel, ierarhia DIKW poate fi privită ca o **scară a valorii informaționale**: pornim de la date brute, le transformăm în informații, apoi în cunoștințe și, în final, aplicăm aceste cunoștințe cu discernământ, sub forma înțelepciunii medicale.

3.3. Informația medicală în spațiul virtual

Înțelegerea diferenței dintre date, informații și cunoștințe devine și mai importantă atunci când mediul de documentare este spațiul virtual, unde cantitatea uriașă de informație disponibilă ridică problema selecției și validării calității. În continuare vom analiza instrumentele prin care putem evalua relevanța surselor online și rolul inteligenței artificiale în acest proces.

Accesul la informație medicală a cunoscut o transformare radicală în ultimele decenii. Dacă altădată studenții și medicii se bazau aproape exclusiv pe manuale și reviste tipărite, astăzi principala sursă de documentare este reprezentată de spațiul virtual, prin baze de date online, motoare de căutare și platforme academice. Avantajele sunt evidente: rapiditatea accesului, volumul uriaș de informații și posibilitatea actualizării permanente. Totuși, această abundență aduce și riscuri, pentru că nu tot ceea ce găsim online este relevant sau credibil.

În practica medicală, documentarea electronică poate începe cu motoare de căutare generale, precum Google, care oferă instantaneu milioane de rezultate. Ele sunt utile pentru o orientare rapidă, dar nu garantează validitatea științifică. De aceea, articolele de pe bloguri sau din surse nesigure nu trebuie confundate cu literatura medicală validată. Chiar și enciclopediile online, precum Wikipedia, pot fi un bun punct de plecare, însă nu au valoare academică directă și nu pot fi citate ca referințe științifice. Mult mai utile sunt platformele

specializate precum PubMed, Google Scholar, Web of Science sau Scopus, care pun la dispoziție articole evaluate de experți. În plus, accesul instituțional la biblioteci electronice – Elsevier, Springer, Oxford Academic sau ProQuest – deschide porțile către publicații de înaltă calitate, chiar dacă multe dintre acestea rămân disponibile doar contra cost.

Problema reală nu mai este lipsa informației, ci selecția ei. Supraîncărcarea cu articole și rezultate face dificilă identificarea celor mai relevante lucrări. Mai mult, calitatea conținutului online este inegală, iar dezinformarea – vizibilă mai ales în domenii sensibile precum vaccinologia sau terapiile alternative – poate influența negativ practica medicală. Din acest motiv, s-au dezvoltat instrumente scientometrice care permit validarea calității unei publicații.

Cel mai simplu indicator este numărul de citări, care arată de câte ori un articol sau un autor este menționat în literatura de specialitate. Totuși, nu orice citare reflectă valoare, unele pot fi critice sau irelevante. Mult mai cunoscut este factorul de impact, care exprimă numărul mediu de citări primite de articolele publicate într-o revistă în ultimii doi ani. El oferă o imagine globală asupra vizibilității și influenței revistei. O variantă mai stabilă este factorul de impact calculat pe cinci ani. Pentru evaluarea autorilor individuali, cel mai utilizat indicator este indicele Hirsch (h-index), care combină productivitatea cu relevanța: un cercetător are h-index 20 dacă a publicat cel puțin 20 de articole, fiecare citat de cel puțin 20 de ori. În plus, indicatori precum CiteScore sau Scimago Journal Rank (SJR) încearcă să măsoare nu doar cantitatea, ci și „greutatea” citărilor, luând în calcul prestigiul revistelor care citează.

În documentarea clinică, acești indicatori nu sunt scopuri în sine, ci instrumente de orientare. De exemplu, un medic rezident care caută informații despre o nouă schemă terapeutică poate începe printr-o căutare simplă pe Google și va obține rapid sute de mii de rezultate, dar calitatea lor este inegală. Dacă își restrânge căutarea la PubMed, accesul este deja limitat la articole validate. Dacă selectează apoi reviste cu factor de impact ridicat și autori cu indice Hirsch consistent, șansele de a găsi date fiabile cresc considerabil. Totuși, chiar și așa, informația găsită trebuie corelată cu ghidurile clinice oficiale și adaptată la contextul pacientului.

În concluzie, informația medicală disponibilă în spațiul virtual este vastă și ușor accesibilă, dar nu întotdeauna sigură. Selectarea surselor corecte

presupune înțelegerea diferenței dintre conținutul liber accesibil și literatura științifică validată. Indicatorii scientometrici nu substituie judecata clinică, dar oferă criterii obiective pentru aprecierea credibilității unei reviste, a unui autor sau a unui articol. În felul acesta, informatica medicală nu doar că facilitează accesul la cunoaștere, ci și ghidează procesul de filtrare și validare a informațiilor, transformând un ocean de date brute din spațiul virtual în cunoștințe clinice utile și aplicabile.

Inteligența artificială ca instrument de documentare medicală

O noutate importantă în ultimii ani este utilizarea modelelor de inteligență artificială conversațională, precum **ChatGPT**, **Microsoft Copilot** sau **Google Gemini**, ca surse rapide de documentare. Spre deosebire de motoarele clasice de căutare, aceste instrumente nu se limitează la listarea unor articole, ci oferă **sinteze în limbaj natural**, construind răspunsuri directe la întrebările utilizatorului.

Avantaje:

- **Accesibilitate:** pot fi folosite de pe orice dispozitiv conectat la internet și oferă răspunsuri aproape instantanee.
- **Capacitate de sinteză:** pot combina informații din surse multiple și le pot prezenta într-o formă mai ușor de înțeles.
- **Personalizare:** răspunsurile pot fi adaptate în funcție de contextul întrebării, nivelul de cunoștințe sau limba utilizată.
- **Sprijin educațional:** pentru studenți, aceste instrumente pot oferi explicații suplimentare la noțiuni dificile sau pot genera exemple clinice.

Riscuri și limitări:

- **Acuratețe variabilă:** modelele nu garantează corectitudinea absolută. Ele pot „inventa” referințe sau pot formula informații parțial eronate, fenomen cunoscut sub numele de *hallucination*.
- **Lipsa surselor transparente:** spre deosebire de PubMed sau Web of Science, răspunsurile AI nu indică întotdeauna clar de unde provin datele.

- **Dependență:** există riscul ca studenții sau chiar medicii să se bazeze exclusiv pe aceste instrumente, fără a mai consulta literatura de specialitate sau ghidurile oficiale.

Probleme etice:

- **Confidențialitatea datelor:** introducerea unor cazuri reale de pacienți în platforme AI poate duce la scurgeri de informații sensibile.
- **Responsabilitatea deciziilor:** modelele AI nu pot substitui raționamentul clinic și responsabilitatea medicului. Decizia medicală trebuie să rămână umană, chiar dacă AI-ul poate furniza sugestii.
- **Bias și echitate:** răspunsurile pot reflecta bias-uri din datele cu care modelele au fost antrenate, ceea ce poate afecta corectitudinea și echitatea informațiilor oferite.

 *Exemplu practic.* Un student la medicină întreabă pe ChatGPT „care sunt cele mai noi linii de tratament pentru cancerul de sân HER2-pozitiv”. Modelul poate oferi o sinteză utilă, menționând terapii țintite precum trastuzumab sau pertuzumab. Totuși, fără verificarea în PubMed sau în ghidurile ESMO, nu există garanția că răspunsul este complet actualizat sau că include toate opțiunile validate.

Instrumentele de inteligență artificială pot fi un sprijin valoros în documentarea medicală, dar ele trebuie utilizate **critic**, ca punct de pornire, nu ca sursă finală: verifică întotdeauna informațiile obținute prin AI în **literatura științifică validată** și în **ghidurile clinice oficiale**, și nu introduce date reale ale pacienților, pentru a proteja confidențialitatea.

Pe lângă prudența în utilizarea inteligenței artificiale, este important de reținut că **modul în care formulezi întrebarea** influențează direct calitatea răspunsului. În practica recentă s-a conturat domeniul numit *prompt engineering* – arta de a construi cereri clare și bine structurate pentru a obține răspunsuri cât mai relevante. În documentarea medicală, aceasta înseamnă să formulezi întrebări **specifice și contextuale**, de exemplu „Care sunt tratamentele de primă linie pentru diabetul zaharat tip 2 conform ghidurilor ADA 2024?” în loc de „Cum se tratează diabetul?”. De asemenea, este util să ceri **structurarea răspunsului** („prezintă pe puncte principalele opțiuni terapeutice” sau „oferă un rezumat de maximum 200 de cuvinte”), ceea ce face

informația mai ușor de integrat. În sfârșit, **întrebările iterative** – adică rafinarea progresivă a cererii pe baza răspunsurilor primite – cresc șansele de a obține un rezultat corect și aplicabil.

Esențial în utilizarea inteligenței artificiale pentru documentare este **definirea clară a contextului**. Modelele AI oferă răspunsuri mai precise atunci când utilizatorul specifică domeniul, scopul și nivelul de detaliu dorit. În medicină, a întreba „Care sunt tratamentele pentru hipertensiune?” poate genera un răspuns vag, amestecând informații pentru toate categoriile de pacienți. În schimb, o întrebare contextualizată precum „Care sunt recomandările terapeutice de primă linie pentru hipertensiunea arterială la un pacient adult de 55 de ani, fără comorbidități, conform ghidului european ESC 2024?” va oferi un răspuns mult mai relevant și apropiat de practica reală.


Astfel, **promptul ideal** combină trei ingrediente: precizarea **scopului** (informație generală, rezumat, listă de recomandări), definirea **contextului clinic** (vârstă, comorbidități, tipul pacientului) și menționarea **surselor dorite** (ghiduri oficiale, PubMed, date OMS).

De reținut despre documentarea medicală modernă

- Folosește **surse validate** (PubMed, Web of Science, ghiduri clinice) ca reper principal.
- Modelele de inteligență artificială (ChatGPT, Copilot, Gemini) pot sprijini documentarea, dar trebuie utilizate **critic**, ca punct de pornire și nu ca sursă finală.
- Definește **clar contextul** atunci când formulezi întrebări către AI (scop, pacient, ghiduri relevante).
- Verifică întotdeauna informațiile generate de AI în **literatura științifică** și nu introduce date reale ale pacienților.

Capitolul 4 – Stocarea datelor

În practica medicală, datele parcurg un adevărat ciclu de viață, de la momentul în care sunt obținute până la utilizarea lor finală în sprijinul deciziei clinice. Fiecare etapă are specificul ei și necesită metode și tehnologii dedicate pentru a asigura corectitudinea, siguranța și relevanța informațiilor.



Achiziția datelor reprezintă prima etapă și este strâns legată de natura informației. Datele pot fi colectate manual, prin completarea unei fișe clinice sau a unui chestionar, sau automat, prin dispozitive medicale, aparate de laborator sau senzori integrați în echipamente de monitorizare.

Odată colectate, datele trebuie **curățate** și **adnotate**, eliminând erorile sau valorile aberante și marcându-se elementele relevante pentru interpretare. În plus, adesea este necesară extragerea informațiilor utile din seturi mai largi de date brute.

Etapa următoare o constituie integrarea și reprezentarea datelor într-un **format comun**, care să permită combinarea informațiilor provenite din surse diferite – de exemplu, date clinice, analize de laborator și imagini medicale. **Standardizarea** este esențială aici, pentru a evita ambiguitățile și a facilita interoperabilitatea.

Pentru a fi disponibile în timp și accesibile mai multor utilizatori, datele trebuie **stocate**. Această stocare se poate realiza în baze de date, baze de cunoștințe sau arhive specializate (cum sunt sistemele PACS pentru imagini medicale).

Datele stocate sunt apoi supuse **analizei**, care poate fi automată (prin algoritmi statistici sau de inteligență artificială) sau vizuală (prin tabele, grafice și imagini interpretate de medic). Analiza este cea care transformă datele brute în informații interpretabile și cu valoare clinică.

În multe cazuri, datele sau rezultatele analizei trebuie **transmise** prin canale de comunicație, de la pacient către medic, de la un laborator la o clinică sau între instituții medicale. Această transmitere trebuie însoțită de măsuri de protecție a datelor, pentru a asigura confidențialitatea și respectarea legislației (de exemplu, GDPR).

În final, datele devin cu adevărat valoroase prin **utilizarea** lor în procesul decizional. Medicul, sprijinit de sisteme informatice, poate stabili diagnosticul și planul terapeutic, iar instituțiile pot lua decizii de management sau politici de sănătate bazate pe analiza integrată a datelor.

Astfel, de la achiziție până la utilizare, datele medicale trec printr-un lanț complex de operații care le conferă sens și utilitate, iar capitolele următoare vor descrie în detaliu modalitățile prin care aceste etape sunt sprijinite de fișiere de date, baze de date și sisteme de gestiune a bazelor de date.

4.1. Fișiere de date

Stocarea datelor reprezintă baza oricărui sistem informatic. În forma cea mai simplă, datele sunt păstrate în **fișiere** – colecții structurate de informații, accesibile pentru citire, actualizare sau prelucrare.

Un fișier de date poate fi păstrat **pe suport fizic (hârtie)** – de exemplu, registrul de consultații sau fișa medicală tradițională – sau **în format digital**, sub forma unui document electronic, a unei foi de calcul sau a unei baze de date. În practica actuală, fișierele digitale tind să înlocuiască aproape complet documentele pe hârtie, dar ambele forme sunt importante pentru a înțelege evoluția stocării datelor medicale.

Un fișier de date este alcătuit din **înregistrări** (records), fiecare dintre ele fiind formată din mai multe **câmpuri** (fields). Fiecare câmp are un **tip de date** (numeric, text, dată calendaristică, logic – adevărat/fals) și o **dimensiune** (număr de caractere sau digiți).

 *Exemplu.* Un fișier care stochează pacienții dintr-o secție conține, pentru fiecare înregistrare, câmpuri precum: *Nume*, *Prenume*, *CNP*, *Vârstă*, *Diagnostic principal*, *Rezultat analiză de laborator*.

Structura fișierului este esențială nu doar pentru interpretarea corectă a datelor, ci și pentru **colectarea lor în mod uniform și consecvent**. Dacă aceeași

informație este înregistrată diferit (de exemplu, sexul pacientului notat uneori „M/F” și alteori „Masculin/Feminin”), fișierul devine dificil de prelucrat automat și apar riscuri de erori în analiză.


Asigurarea unei structuri clare și a unor reguli unitare de completare contribuie la **consistența înregistrărilor** și la menținerea calității datelor medicale. Acest aspect este crucial mai ales atunci când fișierele sunt folosite în scopuri clinice sau epidemiologice, unde orice inconsecvență poate afecta acuratețea diagnosticului sau validitatea concluziilor.

 **Exemplu clinic.** Într-un registru al pacienților cu diabet, câmpul „Tip tratament” poate fi completat de un medic cu „insulină”, de altul cu „ins”, iar de un al treilea cu „tratament insulinic”. Din perspectiva utilizatorului, toate exprimările sunt corecte, dar pentru computer ele reprezintă categorii diferite. O astfel de lipsă de consistență îngreunează analiza statistică și poate duce la raportări eronate privind procentul pacienților tratați cu insulină.


Fișierele de date pot fi gestionate manual (fișiere text, foi de calcul) sau prin aplicații dedicate. În practica medicală, ele sunt întâlnite în:

- **EpiInfo** – instrument dezvoltat de CDC pentru anchete epidemiologice, care permite crearea de fișiere cu variabile personalizate și colectarea datelor în format tabelar;
- **Excel sau alte foi de calcul** – utilizate frecvent pentru evidența pacienților, analize statistice simple și raportări;

Nume <A	>
Vârsta ###	
Căsătorit <Y>	
Data internării <dd/mm/yyyy>	



	A	B	C	D
1	Nume	Vârsta	Căsătorit	Data internării
2				
3				
4				
5				
6				
7				
8				
9				



Field Name	Data Type	Description
PatientID	AutoNumber	
Nume	Text	The field description is optional. It helps you describe the field and is also displayed in the status bar when you select this field on a form. Press F1 for help on descriptions.
Prenume	Text	
Sex	Text	
DataNasterii	Date/Time	
Casatorit	Yes/No	
Observatii	Memo	
Vârsta	Number	

- **Microsoft Access** – care permite o structurare mai complexă și interogări relaționale ale bazei de date;
- **Fișiere DICOM (Digital Imaging and Communications in Medicine)** – care conțin atât imaginea medicală (de exemplu, o

radiografie), cât și metadatele asociate (identitatea pacientului, parametrii tehnici ai aparatului).

Fișierele simple au însă **limitări importante**. În lipsa unui mecanism centralizat de gestionare, apar probleme precum:

- **redundanța datelor** – aceeași informație este stocată în mai multe fișiere, ceea ce crește riscul de inconsistență (de exemplu, același pacient poate fi introdus de mai multe ori în fișiere diferite cu date ușor discordante);
- **dificultăți în partajare** – fișierele individuale sunt greu de utilizat simultan de mai mulți utilizatori;
- **lipsa securității și a controlului accesului** – nu există mecanisme integrate de autentificare sau audit;
- **scalabilitate redusă** – pe măsură ce volumul de date crește, fișierele simple devin greu de gestionat.

De aceea, fișierele reprezintă doar primul pas în stocarea datelor medicale. Pentru a rezolva aceste probleme, s-au dezvoltat structuri mai avansate, cunoscute sub numele de **baze de date**, care vor fi prezentate în secțiunea următoare.

4.2. Baze de date

Definiție și rol

O **bază de date** este o colecție organizată de date, împreună cu relațiile dintre ele, concepută pentru a facilita stocarea, regăsirea și prelucrarea rapidă și sigură a informației. Spre deosebire de fișierele simple, bazele de date urmăresc să reducă redundanța, să asigure consistența și să permită accesul simultan al mai multor utilizatori.

În medicină, bazele de date sunt indispensabile: registrele electronice de pacienți, bazele de date de imagini medicale (PACS), bazele epidemiologice sau arhivele genomice sunt doar câteva exemple.

Crearea și validarea unei baze de date

Pentru a funcționa corect, o bază de date nu se construiește ad-hoc, ci presupune o serie de pași clari, care vizează atât **colectarea datelor**, cât și **validarea lor**.

Colectarea datelor

Primul pas este definirea **structurii înregistrării**. Se stabilește ce câmpuri vor fi incluse, ce tip de date va avea fiecare câmp și care va fi lungimea maximă permisă. De exemplu, un câmp „vârstă” va fi numeric și nu va putea conține text, iar câmpul „nume pacient” va fi alfanumeric, cu o limită de caractere.

Apoi, pentru a asigura uniformitate, se trece la **codificare**, utilizând nomenclatoare și clasificări standardizate. În medicină, cele mai folosite sunt **ICD (International Classification of Diseases)** pentru codificarea diagnosticelor și **SNOMED CT (Systematized Nomenclature of Medicine – Clinical Terms)** pentru termeni clinici detaliați. Codificarea reduce ambiguitatea și facilitează schimbul de informații între sisteme.

Nu în ultimul rând, **instruirea personalului** care completează baza de date este esențială. Chiar și cea mai bine concepută structură poate deveni inutilă dacă utilizatorii nu știu cum să introducă datele în mod consecvent. Formarea asigură coerența și previne erorile de interpretare.

Validarea datelor

După colectare, datele trebuie validate pentru a evita erorile și inconsecvențele. Validarea se realizează la mai multe niveluri:

- **După tipul câmpului** – de exemplu, într-un câmp numeric nu se poate introduce text („treizeci”), iar într-un câmp dată, valoarea trebuie să respecte formatul prestabilit (zi/lună/an).
- **Prin constrângeri** – pot fi definite intervale permise (temperatura corpului între 30–45°C, glicemia între 40–600 mg/dl) sau liste predefinite (sexul pacientului: „M” sau „F”; grupa de sânge: „A, B, AB, 0”).
- **Pe baza relațiilor dintre date** – de exemplu, vârsta pacientului trebuie să fie compatibilă cu data nașterii; un diagnostic de „sarcină” nu poate fi asociat unui pacient de sex masculin; un pacient nu poate fi externat înainte de data internării.


 *Exemplu clinic.* Într-o bază de date de laborator, dacă un utilizator introduce o valoare de hemoglobină de „250 g/dl”, sistemul de validare va semnaliza eroarea, întrucât valoarea depășește intervalul fiziologic posibil. În mod

similar, dacă pentru un pacient bărbat se codifică „diagnostic: sarcină”, relația dintre date va fi invalidată.


Validarea este crucială pentru a garanta că baza de date rămâne **corectă, completă și consistentă**. Ea nu este doar un mecanism tehnic, ci un proces continuu de verificare a calității informației medicale.

Clasificarea bazelor de date

În funcție de arhitectură și de modul de organizare, bazele de date pot fi grupate în mai multe categorii. Cele mai vechi sunt **bazele ierarhice** (Fig. 4.1.a), în care informațiile sunt structurate sub forma unui arbore, cu ramificații și relații de tip „părinte–copil”. Acestea au fost utilizate în primele sisteme clinice, dar s-au dovedit greu de adaptat atunci când datele au devenit mai complexe.



Model ierarhic Fig. 4.1. a)



Model relațional Fig. 4.1. b)

Ulterior au apărut **bazele de tip rețea** (Fig. 4.1. b), care permit stabilirea de legături multiple între înregistrări. Ele au oferit o flexibilitate mai mare decât modelul ierarhic, însă complexitatea lor de implementare le-a limitat utilizarea pe scară largă.

Cea mai răspândită categorie este reprezentată de **bazele relaționale**, introduse la începutul anilor '70 și bazate pe tabele bidimensionale și pe operații algebrice. Acestea sunt utilizate astăzi în majoritatea aplicațiilor clinice, de la registrele electronice de pacienți până la sistemele de laborator.

Pentru aplicații mai specializate există și **bazele de date orientate obiect**, care combină principiile modelului relațional cu avantajele programării orientate obiect. Acestea sunt folosite mai ales în aplicații complexe, unde datele trebuie să fie stocate împreună cu metodele de prelucrare asociate.





Fig. 4.2. Modele structurale ale Bazelor de date


În ultimii ani s-a dezvoltat categoria **bazelor de date nestructurate sau NoSQL**, concepute pentru a gestiona volume foarte mari de date semi-structurate sau nestructurate. Ele sunt deosebit de utile în contextul **Big Data** și al Internetului Obiectelor Medicale (IoMT), unde senzorii și dispozitivele conectate generează permanent fluxuri uriașe de informații.

4.2.1. Baze de date relaționale

Modelul relațional a apărut la începutul anilor '70 și a schimbat fundamental modul în care privim stocarea și organizarea datelor. Spre deosebire de modelele mai vechi, ierarhice sau de tip rețea, acesta se bazează pe o schemă simplă și elegantă: datele sunt organizate în tabele bidimensionale, cu rânduri și coloane. Fiecare rând reprezintă o înregistrare, de exemplu un pacient, iar fiecare coloană descrie o caracteristică a acestuia, cum ar fi vârsta, sexul sau diagnosticul.




Un element esențial al acestor baze este existența unei **chei primare**, un identificator unic pentru fiecare înregistrare. Astfel, același pacient poate fi regăsit fără ambiguități în întreaga bază de date. Relațiile între tabele se stabilesc prin **chei străine**, care permit legarea informațiilor din surse diferite fără a fi nevoie ca acestea să fie repetate. De exemplu, un tabel al pacienților se poate lega de unul al internărilor și de altul al analizelor de laborator, toate având ca referință același identificator unic.



Această organizare aduce mai multe avantaje: datele rămân consistente, redundanța se reduce, iar interogarea lor devine foarte flexibilă. Limbajul SQL, care însoțește bazele relaționale, permite formularea de întrebări precise și obținerea rapidă a răspunsurilor. Într-un spital, de pildă, se poate interoga baza de date pentru a afla câți pacienți au fost internați cu pneumonie într-o anumită perioadă sau care este media valorilor glicemiei într-un anumit grup de vârstă.

Introducerea unei comenzi SQL



În practica medicală, bazele de date relaționale sunt coloana vertebrală a celor mai multe aplicații clinice. Dosarele electronice de sănătate, arhivele de imagini medicale (PACS), registrele epidemiologice sau bazele de date din laboratoarele clinice se bazează, în mare parte, pe acest model.


4.2.2. Baze de date NoSQL

Odată cu explozia datelor medicale – imagini de mare rezoluție, secvențe genomice, milioane de măsurători de la senzori purtabili – modelul relațional a început să își arate limitele. Structura sa fixă și rigidă nu se potrivește întotdeauna cu realitatea complexă a datelor clinice moderne. Aici intervin bazele de date **NoSQL**, adică „Not Only SQL”.

Acestea permit o **stocare mai flexibilă**, adaptată la tipul de date. Unele folosesc modelul **document** (precum MongoDB), unde fiecare pacient poate avea un „dosar” sub formă de document JSON sau XML, cu câmpuri care pot varia de la caz la caz.

XML <pre style="margin: 10px 0 0 20px;"> 1 <?xml version="1.0" encoding="UTF-8"?> 2 <endereco> 3 <cep>31278901</cep> 4 <city>Belo Horizonte</city> 5 <neighborhood>Pampulha</neighborhood> 6 <service>correios</service> 7 <state>MG</state> 8 <street>Av. Presidente Antônio Carlos, 6627</street> 9 </endereco> </pre>	VS.	JSON <pre style="margin: 10px 0 0 20px;"> 1 { 2 "endereco": { 3 "cep": "31278901", 4 "city": "Belo Horizonte", 5 "neighborhood": "Pampulha", 6 "service": "correios", 7 "state": "MG", 8 "street": "Av. Presidente Antônio Carlos, 6627" 9 } 10 } </pre>
--	------------	--

Altele sunt **bazate pe coloane** (de exemplu Cassandra), foarte potrivite pentru date masive, cum ar fi înregistrările continue de la mii de pacienți monitorizați la distanță. Modelele **cheie–valoare**



(Redis) excelează în viteză, fiind folosite pentru loguri de acces sau parametri temporari. În fine, bazele de date **graf** (Neo4j) sunt ideale atunci când vrem să reprezentăm relații complexe – de exemplu rețelele de transmitere a unei boli infecțioase sau conexiunile dintre gene și boli.

Un aspect interesant este că în aceste baze de date trebuie să acceptăm anumite compromisuri: un sistem nu poate fi în același timp perfect **consistent**, mereu **disponibil** și complet **rezistent la erori de rețea** (așa-numita „teoremă CAP”). În medicină, alegerea depinde de context: la monitorizarea unui pacient contează mai mult disponibilitatea datelor, chiar dacă uneori consistența absolută se obține cu întârziere de câteva secunde.

Astfel, bazele NoSQL completează pe cele relaționale, acolo unde volumul, viteza și varietatea datelor depășesc capacitățile unui model clasic.

Putem privi lucrurile simplu: bazele de date **relaționale** sunt ideale atunci când știm foarte bine **structura** datelor – ca într-un registru clasic de pacienți. În schimb, bazele de date **NoSQL** sunt alegerea potrivită atunci când datele sunt extrem de **numeroase, variate și în continuă schimbare** – cum se întâmplă cu datele din genomică, din rețelele sociale sau din dispozitivele IoMT.

În practică, multe sisteme moderne combină ambele tipuri, pentru a beneficia de stabilitatea relaționalului și de flexibilitatea NoSQL.

4.3. Sisteme de gestiune a bazelor de date (SGBD)

O bază de date, oricât de bine ar fi proiectată, are nevoie de un mecanism software care să o administreze. Acest rol este îndeplinit de **Sistemul de Gestiune a Bazelor de Date (SGBD)** – în engleză *Database Management System (DBMS)*. SGBD-ul reprezintă interfața dintre utilizatori și date,

asigurând stocarea sigură, accesul controlat și prelucrarea eficientă a informațiilor.

În domeniul medical, un SGBD se ocupă de gestionarea datelor pacienților, a rezultatelor de laborator, a imaginilor medicale sau a registrelor epidemiologice. El garantează că datele sunt introduse corect, stocate în siguranță și disponibile la momentul potrivit pentru luarea deciziilor.

Funcțiile principale ale unui SGBD

Un SGBD modern îndeplinește mai multe funcții esențiale:

- **Definirea structurii bazei de date** – proiectarea tabelelor, câmpurilor, relațiilor și constrângerilor.
- **Manipularea datelor** – introducerea, modificarea, ștergerea și regăsirea informațiilor; Prin interogări, medicul poate obține rapid liste de pacienți cu un anumit diagnostic, valori statistice sau istoricul complet al unui pacient.
- **Asigurarea integrității și consistenței** – aplicarea regulilor de validare și gestionarea tranzacțiilor (de exemplu, un câmp numeric nu poate conține litere, iar data externării nu poate fi anterioară datei internării);
- **Controlul accesului și securitatea** – stabilirea drepturilor de utilizare și protejarea datelor sensibile. Nu toți utilizatorii trebuie să aibă aceleași drepturi: un medic poate vizualiza și actualiza datele pacienților săi, un cercetător poate accesa doar date anonimizate, iar un administrator poate avea acces la întreaga structură. Acest mecanism este vital pentru protecția datelor cu caracter personal.
- **Recuperarea și backup-ul** – salvarea periodică și restaurarea datelor în caz de avarie;
- **Auditul și trasabilitatea** – înregistrarea tuturor modificărilor pentru a putea reconstitui istoricul datelor.

Un aspect important al funcționării SGBD-urilor este **controlul accesului la date**. Într-un sistem medical, nu toți utilizatorii au aceleași drepturi: medicul curant trebuie să poată vizualiza și actualiza datele pacienților săi, asistentul are acces limitat la anumite informații, cercetătorii pot lucra doar cu date anonimizate, iar administratorii au responsabilitatea gestionării întregii baze. Acest mecanism se realizează prin conturi de utilizator protejate cu parolă și prin atribuirea unor privilegii.




Fig. 4.3. Rolurile sunt colecție de privilegii

Pentru a simplifica administrarea, SGBD-urile folosesc conceptul de **roluri** – colecții predefinite de privilegii care pot fi acordate unui utilizator sau unui grup de utilizatori. În acest fel, un medic rezident poate primi rapid toate drepturile necesare pentru vizualizarea și completarea fișelor, fără a fi nevoie să i se configureze manual fiecare permisiune.

Limbajul SQL

Pentru a lucra cu bazele de date relaționale, s-a dezvoltat un limbaj standardizat numit **SQL (Structured Query Language)**. El nu este un limbaj de programare în sens clasic, ci un **limbaj declarativ**, ceea ce înseamnă că utilizatorul descrie *ce rezultat dorește*, iar SGBD-ul decide *cum să obțină acel rezultat*.

SQL este împărțit în mai multe componente, fiecare având un rol specific: unele se ocupă de **definirea structurii bazei de date**, altele de **manipularea datelor**, de **gestionarea accesului** sau de **controlul tranzacțiilor**. În practica medicală, acest limbaj permite medicului sau cercetătorului să extragă rapid informațiile necesare dintr-o bază complexă – de exemplu, lista pacienților cu un anumit diagnostic, valorile medii ale analizelor sau istoricul internărilor.

▪ SELECT	Interogarea BD
▪ INSERT ▪ UPDATE ▪ DELETE	Limbaj de manipulare a datelor Data manipulation language (DML)
▪ CREATE ▪ ALTER ▪ DROP ▪ RENAME ▪ TRUNCATE	Limbaj de definire a datelor Data definition language (DDL)
▪ COMMIT ▪ ROLLBACK ▪ SAVEPOINT	Limbaj de control al tranzacțiilor Transaction control language (TCL)
▪ GRANT ▪ REVOKE	Limbaj de control al datelor Data control language (DCL)

a) DDL – Data Definition Language

Este limbajul prin care se definește structura bazei de date. Cu ajutorul său se creează și se modifică tabele, câmpuri și relații.

 *Exemplu.* Comanda `CREATE TABLE Pacienti (CNP CHAR(13) PRIMARY KEY, Nume VARCHAR(50), Varsta INT, Diagnostic VARCHAR(100));` definește tabelul „Pacienți” cu câmpurile esențiale pentru identificare și diagnostic.

b) DML – Data Manipulation Language

Permite lucrul direct cu datele: inserare, actualizare, ștergere și interogare.

 *Exemplu.* `SELECT Nume, Varsta FROM Pacienti WHERE Diagnostic='Diabet';` returnează lista pacienților cu diagnostic de diabet.

c) DCL – Data Control Language

Gestionează drepturile de acces la date. Administratorii pot acorda sau restricționa permisiuni.

 *Exemplu.* `GRANT SELECT ON Pacienti TO Rezident;` acordă rezidenților dreptul de a vizualiza tabelul „Pacienți”, dar nu de a-l modifica.

d) TCL – Transaction Control Language

Asigură integritatea tranzacțiilor, adică a grupurilor de operații care trebuie executate complet sau deloc.

 *Exemplu.* La internarea unui pacient, datele sunt adăugate simultan în tabelul *Pacienți* și în tabelul *Internări*. Dacă una dintre operații eșuează, ambele sunt anulate prin ROLLBACK, evitând inconsistența.

Interogări prin QBE (Query By Example)

Pe lângă limbajul SQL, unele SGBD-uri oferă interfețe grafice care facilitează formularea interogărilor, chiar și pentru utilizatorii fără cunoștințe tehnice avansate. Un exemplu este Query By Example (QBE), implementat în Microsoft Access.

QBE permite construirea interogărilor printr-o interfață vizuală, în care utilizatorul selectează tabelele și câmpurile de interes, apoi completează criteriile într-o grilă. De exemplu, pentru a obține lista pacienților cu vârsta peste 65 de ani și diagnostic de hipertensiune, utilizatorul nu trebuie să scrie manual comanda SQL, ci doar să introducă valoarea „>65” în coloana „Vârsta” și termenul „hipertensiune” la „Diagnostic”.

Avantajul QBE este că oferă o metodă intuitivă de interogare, potrivită pentru personalul medical care nu are experiență în limbaje de programare. În același timp, interogarea QBE generează „în spate” un cod SQL, care poate fi vizualizat și editat ulterior:

```
SELECT Nume, Prenume, Varsta, Diagnostic
FROM Pacienti
WHERE Varsta > 65 AND Diagnostic = "hipertensiune";
```

Astfel, QBE oferă o metodă vizuală de a construi interogări, iar SGBD-ul traduce automat instrucțiunile în SQL. Acest lucru permite utilizatorilor începători să obțină rapid rezultate, dar și să învețe treptat structura limbajului SQL.

Tipuri de SGBD și utilizări în medicină

Cele mai răspândite SGBD-uri relaționale sunt **Oracle Database**, **Microsoft SQL Server**, **MySQL** și **PostgreSQL**, utilizate pentru dosarele electronice de sănătate, registre de pacienți și sisteme de laborator.

Pentru volume mari de date nestructurate sunt preferate SGBD-urile NoSQL, precum **MongoDB**, **Cassandra** sau **Neo4j**, folosite în bioinformatică, analiză genomică sau rețele epidemiologice.

Creșterea exponențială a volumului de date medicale a dus la apariția unor tehnologii dedicate, reunite sub umbrela conceptului de **Big Data**. Spre deosebire de bazele de date clasice, care gestionează seturi moderate de informații structurate, Big Data presupune lucrul cu date masive, eterogene și aflate în flux continuu.

Big Data	Small Data
>TB, PB	GB
30 KiB - 30 GiB / secundă	Date fixe

Conceptul de **Big Data** a fost definit inițial prin trei caracteristici fundamentale, cunoscute sub numele de „cei trei V”:

- **Volumul** – cantitatea uriașă de date generate (de exemplu, arhive de imagini medicale, date genomice sau milioane de înregistrări provenite de la senzori portabili).
- **Viteza (Velocity)** – rapiditatea cu care aceste date sunt produse și trebuie procesate (date în timp real de la monitoare din terapie intensivă sau de la dispozitive IoMT).
- **Varietatea** – diversitatea tipurilor de date, de la texte clinice și fișiere numerice la imagini, semnale și fișiere audio-video.

Ulterior, pe măsură ce analiza datelor a devenit mai complexă, au fost adăugate alte dimensiuni, ajungând la **12 „V”**:

1. **Volumul** – mărimea dataset-urilor, de ordinul terabytes–petabytes.
2. **Viteza** – fluxuri de date continue care necesită procesare aproape instantanee.

3. **Varietatea** – date structurate, semi-structurate și nestructurate.
4. **Veridicitatea (Veracity)** – corectitudinea și credibilitatea datelor, mai ales în contextul erorilor de măsurare sau al datelor lipsă.
5. **Valoarea (Value)** – relevanța practică a datelor: nu doar cantitatea contează, ci și utilitatea pentru decizie.
6. **Variabilitatea (Variability)** – surse de date cu comportament dynamic, evolutiv
7. **Vizualizarea (Visualization)** – date complexe ce pot fi reprezentate în diverse moduri pentru a fi interpretate de clinicieni.
8. **Validitatea (Validity)** – măsura în care datele corespund fenomenului real pe care îl descriu.
9. **Volatilitatea (Volatility)** – durata de viață a datelor: unele trebuie păstrate pe termen lung (ex. dosarul pacientului), altele sunt valide doar temporar.
10. **Vulnerabilitatea (Vulnerability)** – expunerea la riscuri de securitate și la pierderi de confidențialitate.
11. **Versatilitatea (Versatility)** – capacitatea de a utiliza datele în contexte diferite, de la clinică la cercetare.
12. **Vagi (Vagueness)** – semnificație neclară pentru un anumit context.

În practică, Big Data medical înseamnă infrastructuri distribuite, capabile să proceseze simultan volume uriașe de informații. Tehnologii precum **Hadoop** sau **Apache Spark** permit fragmentarea și analiza paralelă a datelor pe mai multe servere. În paralel, bazele de date NoSQL și soluțiile de **cloud computing** facilitează scalarea și accesul rapid la resurse.

Exemple de aplicații medicale includ analiza în timp real a datelor provenite din secțiile de terapie intensivă, corelarea registrelor naționale pentru evaluarea riscului epidemiologic, sau integrarea bazelor genomice pentru identificarea predispozițiilor genetice.

Totuși, utilizarea Big Data ridică și provocări: necesitatea unor standarde de interoperabilitate, costuri mari de infrastructură, dar mai ales probleme legate de protecția datelor și de etica utilizării lor.

De reținut

- Fișierele de date sunt structurate organizate de date pe hârtie sau digitale, dar bazele de date asigură consistență și acces multi-utilizator.
- Crearea unei baze de date presupune definirea structurii, codificare și validare riguroasă a datelor.
- Bazele relaționale sunt dominante în aplicațiile clinice, iar bazele NoSQL oferă flexibilitate pentru Big Data și IoMT.
- SGBD-urile gestionează datele prin limbaje specializate cum este SQL, asigurând integritatea, securitatea și accesul controlat la date.
- Big Data și cloud computing extind capacitatea de stocare și analiză, dar ridică noi provocări legate de protecția datelor.

Partea II

De la informație la cunoaștere

Capitolul 5 – Prelucrarea datelor numerice și calitative

Datele medicale, odată colectate și stocate în fișiere sau baze de date, nu au valoare reală decât atunci când sunt **analizate și interpretate**. Scopul prelucrării datelor este transformarea valorilor brute – rezultate de laborator, semne vitale, scoruri clinice sau răspunsuri la chestionare – în informații care pot fi înțelese, comparate și utilizate în procesul medical.

Analiza datelor urmărește în primul rând să descrie și să rezume informațiile disponibile, să evidențieze modele și tendințe, dar și să testeze ipoteze sau să descopere relații ascunse între variabile. În acest sens, metodele de prelucrare statistică devin un instrument indispensabil nu doar pentru cercetare, ci și pentru practica clinică de zi cu zi: de la evaluarea evoluției unui pacient până la fundamentarea ghidurilor terapeutice.

Tipuri de analiză

Atunci când vorbim despre analiza datelor medicale, este util să înțelegem că există mai multe niveluri de profunzime, în funcție de întrebarea la care dorim să răspundem.

- **Analiza descriptivă** răspunde la întrebarea „*ce s-a întâmplat?*”. Ea rezumă informațiile, de exemplu prin prezentarea numărului de pacienți cu un anumit diagnostic într-un an sau media glicemiei într-un lot de pacienți.
- **Analiza de diagnoză** merge mai departe și caută răspunsul la „*de ce s-a întâmplat?*”. De exemplu, poate investiga dacă frecvența crescută a unei boli este asociată cu factori de risc precum obezitatea sau fumatul.
- **Analiza predictivă** încearcă să răspundă la „*ce se va întâmpla?*”. Folosind modele statistice și algoritmi de învățare automată, se pot estima riscurile viitoare, de pildă probabilitatea de a dezvolta diabet într-un anumit interval de timp.
- **Analiza prescriptivă** caută să ofere răspunsul la „*ce ar trebui făcut și de ce?*”. În acest caz, analiza nu doar descrie sau anticipează, ci și recomandă decizii optime. În medicină, aceasta se concretizează în ghiduri terapeutice bazate pe dovezi, dar și în sisteme moderne de suport decizional integrate în EHR.

Calitatea datelor

Indiferent de nivelul analizei, rezultatele depind în mod direct de **calitatea datelor**. Două concepte cheie sunt **acuratețea** și **precizia**.

- **Acuratețea** arată cât de apropiate sunt măsurătorile de valoarea reală. Un laborator cu reactivi corect calibrați produce rezultate cu acuratețe ridicată.
- **Precizia** descrie gradul de repetabilitate al măsurătorilor. Dacă același test de laborator aplicat de mai multe ori pe aceeași probă dă rezultate foarte apropiate, atunci testul este precis.




Fig. 5.1. A) Acuratețe bună, Precizie mică B) Acuratețe mică, Precizie mare

Ideal, o metodă de măsurare trebuie să fie atât precisă, cât și exactă. Spre exemplu, un tensiometru care arată constant 150 mmHg la un pacient a cărui tensiune reală este 140 mmHg este **precis** (valorile sunt stabile), dar nu **exact** (valoarea măsurată diferă de cea reală).

Astfel, în orice studiu sau analiză medicală, verificarea acurateței și preciziei este un pas esențial înainte de interpretarea datelor.

Colectarea datelor

Înainte de a analiza datele, trebuie să fim atenți la **modul în care ele sunt colectate și organizate**. Calitatea analizei depinde direct de calitatea sursei de informații.

În medicină, datele provin din surse foarte variate: fișe electronice ale pacienților, registre epidemiologice, laboratoare clinice, imagistică medicală, dar și din chestionare aplicate pacienților. Fiecare dintre aceste surse poate aduce cu sine erori, valori lipsă sau neconcordanțe.

De aceea, după colectare, datele trebuie supuse unor etape de **prelucrare inițială**:

- **Curățarea datelor** – eliminarea sau corectarea valorilor imposibile. De exemplu, o valoare de „-15 mg/dl” pentru glicemie este evident eronată și trebuie verificată.
- **Completarea valorilor lipsă** – prin metode statistice sau prin verificarea în alte surse.
- **Gestionarea valorilor extreme (outliers)** – acestea pot fi fie erori de măsurare, fie situații clinice rare. De exemplu, o glicemie de 1000 mg/dl poate părea un outlier, dar dacă este confirmată, ea reprezintă o situație reală de urgență medicală.
- **Verificarea consistenței** – asigurarea că datele diferitelor variabile nu se contrazic. Un exemplu ar fi un pacient trecut ca „sex masculin” dar având diagnostic de „sarcină”.

Pentru a înțelege modul în care se analizează datele medicale, este esențial să distingem între **tipurile de date** (numerice sau calitative) și să alegem metodele adecvate fiecărui tip. În continuare vom prezenta principalele categorii de date utilizate în medicină și modul în care acestea pot fi organizate și analizate.

5.1. Tipuri de date medicale

Înainte de a analiza un set de date, este esențial să știm **ce tip de date avem în față**, deoarece metodele de prelucrare diferă în funcție de natura informației. În medicină întâlnim două categorii majore: **date cantitative (numerice)** și **date calitative**.

Datele numerice se exprimă prin valori măsurabile și pot fi de două feluri:

- **continue**, atunci când pot lua orice valoare într-un interval. Un exemplu clasic este tensiunea arterială sau glicemia: pot avea valori variabile, cu zecimale, și nu sunt limitate la un număr fix de posibilități.
- **discrete**, atunci când reprezintă numărări și pot lua doar valori întregi. De exemplu, numărul de leucocite într-un milimetru cub de sânge sau numărul de copii într-o familie.

Datele calitative descriu atribute sau categorii, nu mărimi măsurabile. Acestea pot fi:

- **nominale**, atunci când valorile sunt doar etichete fără o ordine între ele. Sexul pacientului (masculin/feminin), grupa sanguină (A, B, AB, 0) sau tipul de vaccin administrat sunt exemple de date nominale.
- **ordinale**, atunci când categoriile pot fi ordonate, dar distanța dintre ele nu este neapărat constantă. Stadiile unei boli (I, II, III, IV), scorurile de durere de la „absentă” la „severă” sau clasificarea unei tumori ca „bine”, „moderată” sau „slab diferențiată” sunt date ordinale.

Clasificarea corectă a datelor este **primul pas esențial în analiza lor**. De exemplu, dacă tratăm o variabilă ordinală ca și cum ar fi numerică (ex. scorul durerii), putem ajunge la concluzii eronate. În schimb, recunoașterea naturii datelor ne ajută să alegem testele statistice adecvate și să evităm interpretările incorecte.

Pe lângă împărțirea clasică în date numerice și calitative, există și o clasificare bazată pe **scările de măsură**:

- **Scara nominală**: variabile ce indică doar apartenența la o categorie, fără ordine între valori. Exemplu: sexul pacientului, grupa de sânge.
- **Scara ordinală**: variabile ce reflectă o ordine între categorii, dar distanța dintre trepte nu este măsurabilă. Exemplu: stadiile unei boli (I–IV), scorul durerii (ușoară, moderată, severă).
- **Scara de interval**: variabile numerice în care diferența dintre valori are semnificație, dar nu există un „zero absolut”. Exemplu: Diferența dintre 36°C și 38°C este aceeași ca între 38°C și 40°C (2 grade), dar nu putem spune că 40°C înseamnă „dublu” față de 20°C, deoarece zero-ul este arbitrar.
- **Scara de rație**: variabile numerice cu zero absolut care semnifică absența completă a fenomenului măsurat. Acest lucru permite nu doar calcularea diferențelor, ci și a rapoartelor. Exemplu: greutatea corporală (0 kg = lipsa masei), durata unei spitalizări (0 zile = pacientul nu a fost internat), frecvența cardiacă (zero bătăi pe minut = stop cardiac, iar o frecvență de 120 bpm este de două ori mai mare decât una de 60 bpm).

Această clasificare este importantă pentru că determină metodele de analiză ce pot fi aplicate. De exemplu, putem calcula media și raportul între două valori doar pentru date măsurate pe scara de rație, dar nu și pentru date ordinale sau nominale.

5.2. Organizarea și reprezentarea datelor

După colectare, primul pas în prelucrarea datelor medicale este **organizarea lor într-o formă clară și ușor de interpretat**. Valorile individuale, chiar dacă sunt corecte, devin greu de urmărit atunci când seturile de date sunt mari. De aceea, se folosesc metode de grupare, sinteză și vizualizare care să evidențieze structura și tendințele din date.


O modalitate de bază este organizarea datelor în **tabele și distribuții de frecvență**. Această etapă este critică: chiar și cele mai sofisticate metode statistice sau algoritmi de inteligență artificială nu pot compensa date de slabă calitate. Un tabel de frecvență arată de câte ori apare fiecare valoare sau categorie. De exemplu, dacă analizăm grupa sanguină a unui lot de pacienți, putem vedea câți pacienți au grupa A, câți grupa B și așa mai departe. În cazul datelor numerice, valorile sunt grupate în **intervale de clasă** (de exemplu, pacienți cu glicemie între 70–99 mg/dl, între 100–139 mg/dl etc.), iar frecvențele arată distribuția acestora.

Pe lângă tabele, o importanță deosebită o au **reprezentările grafice**, care oferă o imagine intuitivă a datelor. Printre cele mai utilizate:

- **Histograma**, potrivită pentru variabile numerice continue, arată distribuția valorilor într-un eșantion. De exemplu, distribuția tensiunii arteriale într-un grup de pacienți hipertensivi.
- **Diagramele de bare**, frecvent folosite pentru date calitative, reprezintă vizual proporția pacienților pe categorii (de exemplu, numărul cazurilor pe fiecare diagnostic).
- **Diagramele circulare (pie chart)** sunt utile pentru a arăta proporții sau structura unui lot, cum ar fi repartitia pe sexe sau pe grupe de vârstă.
- **Boxplot-ul (diagrama cutiei)** este folosit pentru a descrie distribuția unei variabile numerice și pentru a evidenția valorile extreme (outliers).

Pe lângă aceste reprezentări, există și alte tipuri de grafice utile în analiza datelor medicale:

- **Graficul liniar** – evidențiază variația unei variabile în timp. Este foarte des folosit pentru monitorizarea parametrilor unui pacient, de exemplu evoluția glicemiei pe parcursul unei săptămâni sau curba temperaturii în timpul unei infecții.
- **Norul de puncte (scatter plot)** – arată relația dintre două variabile numerice. Poate fi utilizat pentru a observa corelații, de exemplu între indicele de masă corporală și valorile tensiunii arteriale.
- **Graficul de tip „stacked” (bare suprapuse)** – evidențiază structura unui total. Este util, de pildă, pentru a arăta repartitia cazurilor de cancer pe tipuri histologice și pe grupe de vârstă.
- **Graficul radar („păianjen”)** – permite compararea mai multor variabile simultan. În medicină, poate fi folosit pentru a vizualiza scoruri obținute la diferite dimensiuni ale calității vieții la un grup de pacienți.
- **Hărțile tematice** – folosesc reprezentări spațiale pentru a arăta incidența cazurilor pe județe, regiuni sau țări. Acestea sunt foarte utile pentru decizii de sănătate publică.



Alegerea tipului de grafic depinde de **scopul analizei** și de **tipul de date**. În practică, combinația dintre tabele, grafice simple și vizualizări avansate oferă cea mai bună imagine asupra datelor clinice.

Aceste metode de organizare și reprezentare grafică nu sunt doar instrumente statistice, ci și **mijloace de comunicare medicală**. O diagramă clară sau un tabel bine structurat poate transmite rapid informații relevante unui coleg, unui manager de spital sau chiar pacientului însuși.

 *Exemplu* – de la valori brute la histogramă

Să presupunem că am colectat valorile glicemiei (mg/dl) pentru un grup de 15 pacienți: 92, 105, 98, 110, 87, 150, 130, 95, 102, 115, 140, 99, 108, 125, 135


1. **Date brute:** Valorile individuale nu ne spun mare lucru la prima vedere și sunt greu de comparat.
2. **Tabel de frecvență:** Organizăm datele în **intervale de clasă** (de exemplu, din 10 în 10 mg/dl):

Interval glicemie (mg/dl)	Număr pacienți
80–99	5
100–119	5
120–139	3
140–159	2

Acum putem vedea clar că majoritatea pacienților se află în intervalul 80–119 mg/dl.

3. **Histograma:** Reprezentăm grafic frecvențele. Fiecare interval devine o bară a cărei înălțime este proporțională cu numărul de pacienți.

Interpretarea devine imediată: distribuția glicemiilor arată că cei mai mulți pacienți sunt aproape de limita normală, dar există și valori mai ridicate care sugerează hiperglicemie.



5.3. Analiza univariată

Analiza univariată se referă la studiul **unei singure variabile** la un moment dat. Ea are ca scop descrierea caracteristicilor generale ale distribuției: unde se concentrează valorile (tendința centrală), cât de mult variază acestea (dispersia) și cum se prezintă forma distribuției (asimetrie, valori extreme).

Indicatorii tendinței centrale

Atunci când dorim să descriem o variabilă, prima întrebare este: „*în jurul cărei valori se concentrează observațiile?*”. Pentru a răspunde, folosim indicatorii de tendință centrală, care rezumă valorile printr-o singură măsură reprezentativă pentru întregul set de date. Cei mai utilizați sunt media aritmetică, mediana și modulul.

1. **Media aritmetică** – pentru variabile **cantitative**

$$\bar{X} = \frac{\sum_{i=1}^N X_i}{N} = \frac{X_1 + X_2 + \dots + X_N}{N} \quad (5.1)$$

unde X_i sunt valorile observate și N este numărul de observații.

 *Exemplu:* pentru valorile tensiunii sistolice 110, 130, 110, 150, 100 media este

$$\bar{X} = (110+130+110+150+100)/5 = 120 \text{ mmHg}$$

2. **Mediana** este valoarea care împarte setul de date în două părți egale **după ordonare**. Se folosește pentru variabile **ordinale**, dar poate fi utilă și pentru variabilele numerice în cazul distribuțiilor asimetrice.

Pentru valorile din exemplul anterior, după ordonare șirul de valori devine 100, 110, **110**, 130, 150 iar mediana este **110**

În cazul unui **șir par de valori**, mediana se calculează ca medie a celor două valori centrale.

 *Exemplu:* pentru șirul (deja ordonat) 100, 110, **110, 120**, 130, 150 mediana este $(110+120)/2=115$

3. **Modulul (Moda)** se folosește îndeosebi pentru variabile **calitative**. Este valoarea care apare cel mai frecvent.

 *Exemplu:* în setul 100, **120, 120**, 140, 150 modulul este 120.

În practică: media este cea mai sensibilă la valori extreme, în timp ce mediana oferă o măsură mai robustă atunci când distribuția este asimetrică. Modulul este util pentru date calitative sau pentru variabile cu valori discrete (ex. grupa sanguină).

Indicatori de dispersie

La descrierea unei variabile nu este suficient să știm doar valoarea centrală a datelor. Două loturi de pacienți pot avea aceeași medie a glicemiei, dar cu o răspândire foarte diferită a valorilor individuale. De aceea, analizăm și **indicatorii de dispersie**, care descriu cât de mult variază datele față de tendința centrală. Printre acești indicatori se numără intervalul de valori, varianța, deviația standard și coeficientul de variație.

1. Intervalul de variație

$$R = X_{\max} - X_{\min} \quad (5.2)$$

 *Exemplu:* dacă glicemia variază între 80 și 200 mg/dl, intervalul este 120 mg/dl.

2. Varianța și deviația standard

$$S^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n-1} \quad (5.3)$$

$$S = \sqrt{S^2} \quad (5.4)$$

 *Exemplu:* pentru valorile glicemiei 90, 100, 110 media este 100, varianța este

$$S^2 = \frac{(90-100)^2 + (100-100)^2 + (110-100)^2}{3-1} = 100, \text{ iar deviația standard este } S=10.$$

3. Coeficientul de variație

$$CV = \frac{S}{\bar{X}} \times 100\% \quad (5.5)$$

 *Exemplu:* pentru glicemia cu media 100 și S=10, coeficientul de variație este 10%.

În practică: abaterea standard arată „răspândirea” valorilor în jurul mediei, iar coeficientul de variație permite compararea variabilității între seturi diferite de date (ex. glicemie vs. tensiune arterială).

Distribuția normală

Un aspect important în analiza univariată este **forma distribuției** datelor. În medicină, multe variabile biologice (înălțimea, greutatea, tensiunea arterială, glicemia) tind să urmeze o **distribuție normală** sau „în formă de clopot” (*bell curve*).

Distribuția normală are câteva proprietăți esențiale:

- Este **simetrică** față de medie.
- Media, mediana și modulul coincid.
- Aproximativ **68%** din observații se află în intervalul $\bar{X} \pm 1S$, **95%** în intervalul $\bar{X} \pm 2S$, și **99,7%** în intervalul $\bar{X} \pm 3S$. Această regulă se numește „**regula 68–95–99,7**”.




Fig. 5.5 – Distribuția normală și regula 68–95–99,7

 **Exemplu:** dacă media tensiunii arteriale sistolice într-un lot de pacienți este de 130 mmHg, cu o abatere standard de 10 mmHg, atunci pentru TAS:

- Aproximativ 68% dintre pacienți vor avea valori între 120 și 140 mmHg.
- Aproximativ 95% dintre pacienți vor avea valori între 110 și 150 mmHg.

Distribuția normală are o importanță majoră pentru inferența statistică: multe teste și metode (inclusiv intervalele de încredere și testele de semnificație) se bazează pe această presupunere. Totuși, în practică nu toate variabilele medicale respectă exact distribuția normală, motiv pentru care există și metode non-parametrice.

5.4. Inferența statistică

Populație și eșantion

În cercetarea medicală, este rar posibil să măsurăm toți indivizii dintr-o populație (de exemplu, toți pacienții hipertensivi dintr-o țară). De aceea, se lucrează cu un **eșantion** – un subset reprezentativ al populației.

- **Populația** = ansamblul tuturor indivizilor de interes.
- **Eșantionul** = grupul de indivizi observați direct, ales astfel încât să reflecte cât mai bine populația.

Parametri și estimatori

O caracteristică a populației (de exemplu, media tensiunii arteriale sau proporția pacienților cu diabet) se numește **parametru**. Această valoare este de obicei necunoscută.

Ceea ce calculăm pe baza eșantionului (media eșantionului, proporția observată) se numește **estimator**.

- **Estimator punctual** = o singură valoare folosită pentru a aproxima parametrul populației (ex. media eșantionului ca estimare a mediei populației). Este ca și cum un pescar ar trage cu o săgeată după un pește (Fig. 5.2. stg.): dacă are noroc și țintește exact, îl nimerește; dacă nu, rămâne doar cu o estimare punctuală, care poate fi mai aproape sau mai departe de valoarea reală.
- **Estimator prin interval** = un interval de valori care conține, cu o anumită probabilitate, parametrul real (interval de încredere). Este ca și cum același pescar ar arunca un năvod (Fig. 5.2. dr.): poate nu prinde exact peștele în centrul plasei, dar are șanse mult mai mari ca peștele să fie undeva în interiorul acesteia.



Fig. 5.2. Pescar trăgând cu săgeata (stg.) sau aruncând un năvod (dr.)

Foto by Water Alternatives Photos, CC BY-NC 2.0

Intervalele de încredere

Pentru a exprima incertitudinea oricărui estimator punctual, folosim **intervalele de încredere**.

Formula generală pentru media eșantionului este:

$$IC_{95\%} = \bar{X} \pm Z_{\frac{\alpha}{2}} S \sqrt{n} \quad (5.6)$$

unde $\bar{X}$ este media eșantionului, S = deviația standard, n = dimensiunea eșantionului și $Z_{\alpha/2} = 1,96$ pentru un nivel de încredere de 95%. $\frac{S}{\sqrt{n}}$ reprezintă eroarea standard a mediei, indicator de dispersie care arată variația mediilor eșantioanelor în jurul mediei reale a populației.

 *Exemplu clinic.* Să presupunem că am selectat un eșantion de 100 de pacienți. Media tensiunii arteriale sistolice a fost 135 mmHg, cu o deviație standard de 15 mmHg. Intervalul de încredere 95% pentru media populației este: $IC_{95\%} = 135 \pm 1,96 \cdot 15 = 135 \pm 2,94$.

Deci putem afirma că, cu un nivel de încredere de 95%, media tensiunii arteriale în populația din care provin pacienții se află între **132,1 și 137,9 mmHg**.

5.4. Analiza bivariată

Dacă analiza univariată descrie o singură variabilă, analiza bivariată urmărește să evidențieze **relația dintre două variabile**. În funcție de natura lor

(numerice sau calitative), se folosesc metode diferite pentru a testa dacă există o asociere semnificativă.

Relații între două variabile numerice – corelație și regresie

Atunci când ambele variabile sunt numerice, prima întrebare este: „*există o relație liniară între ele?*”.

Coefficientul de corelație Pearson (r) măsoară intensitatea și direcția relației liniare dintre două variabile numerice (cu valori între -1 și +1).

$$r = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2 \sum (Y_i - \bar{Y})^2}} \quad (5.7)$$

Un r pozitiv arată o relație directă (când X crește, crește și Y), iar un r negativ arată o relație inversă. O valoare r apropiată de 0 (între -0.2 și +0.2) indică absența corelației liniare.

În absența corelației liniare pot fi investigate și alte tipuri de asocieri non-liniare, cum sunt cele logaritmice sau exponențiale.

Existența unei corelații între două variabile nu demonstrează cauzalitatea ci doar justifică o analiză mai avansată pentru identificarea factorilor cauzali.

 *Exemplu clinic:* corelația dintre **indicele de masă corporală (IMC)** și **glicemie**. Un $r = 0,65$ arată o asociere pozitivă moderată: pacienții cu IMC mai mare tind să aibă glicemii mai ridicate.






Fig. 5.3 Interpretarea coeficientului de corelație

Coeficientul Spearman (ρ) este o alternativă non-parametrică, folosită atunci când datele nu respectă distribuția normală sau când avem valori ordinale.

Regresia liniară simplă realizează un model de predicție al unei variabile pe baza evoluției celeilalte variabile și descrie relația printr-o ecuație de tip:

$$Y = a + b \times X \quad (5.8)$$

unde a este interceptul și b este panta (cât se modifică Y pentru o unitate de creștere a lui X).



Relații între două variabile calitative – testul chi-pătrat

Dacă ambele variabile sunt calitative, se folosește **testul chi-pătrat al independenței**. Acesta compară distribuția observată într-un tabel de contingență cu distribuția așteptată în cazul în care variabilele ar fi independente.

$$\chi^2 = \sum \frac{(O_i - E_i)^2}{E_i} \quad (5.9)$$

unde O_i = frecvențele observate și E_i = frecvențele așteptate, i = clasele descrise în tabel.

Exemplu clinic: asocierea dintre **sexul pacientului** (M/F) și **prezența hipertensiunii** (da/nu) ($i=2$). Dacă testul arată o valoare χ^2 semnificativă ($p < 0,05$), putem concluziona că hipertensiunea este asociată cu sexul.

		Hipertensiune	
		Da	Nu
Sex	M	23	15
	F	32	17

Relații între o variabilă numerică și una calitativă

Dacă avem o variabilă numerică (de ex. tensiunea arterială) și una calitativă (de ex. sexul), putem compara mediile între grupuri.

- **Testul t pentru eșantioane independente:** verifică dacă media unei variabile numerice diferă semnificativ între două grupuri.
- **Testul Mann–Whitney U:** alternativă non-parametrică, utilizată atunci când datele nu sunt distribuite normal.

 *Exemplu clinic:* compararea valorii medii a tensiunii arteriale sistolice la bărbați vs. femei. Dacă testul t arată o diferență semnificativă ($p < 0,05$), putem afirma că sexul influențează valorile tensiunii arteriale.

În toate testele statistice, cum sunt și cele descrise la 5.4.2 și 5.4.3, rezultatul este interpretat prin valoarea **p (probabilitatea de eroare)**; dacă $p < 0,05$, diferența sau asocierea observată este considerată **statistic semnificativă**, ceea ce înseamnă că este foarte puțin probabil să fi apărut întâmplător.

5.5. Analiza multivariată

Analiza multivariată se ocupă de situațiile în care sunt studiate simultan **mai multe variabile** pentru a înțelege relațiile complexe dintre ele. În medicină, rareori un fenomen clinic depinde de un singur factor: de obicei, evoluția unui pacient este influențată de vârstă, sex, stil de viață, comorbidități și tratamente. Analiza multivariată permite integrarea acestor factori într-un model comun, fiind esențială pentru cercetarea modernă. Ea constituie fundamentul pentru medicina bazată pe dovezi și pentru dezvoltarea algoritmilor de inteligență artificială.

Regresia multiplă

- **Regresia liniară multiplă** extinde regresia simplă, permițând explicarea unei variabile dependente numerice (de exemplu, tensiunea arterială) prin mai mulți predictorii (vârstă, greutate, IMC, consum de sare).

Formula generală este:

$$Y = a + b_1X_1 + b_2X_2 + \dots + b_kX_k \quad (5.10)$$

- **Regresia logistică** este folosită atunci când variabila dependentă este binară (de exemplu, „boală prezentă/absentă”). În cercetarea medicală,

regresia logistică este metoda clasică pentru estimarea **riscului** și pentru calcularea **odds ratio**.

 *Exemplu clinic:* Vrem să modelăm **nivelul glicemiei** (mg/dl) la pacienți, în funcție de trei factori: **Vârsta** (ani), **IMC** (kg/m²) și **Nivelul de activitate fizică** (scor de la 1 = sedentar la 5 = foarte activ).

Forma generală a modelului:

$$\text{Glicemie} = \beta_0 + \beta_1 \times \text{Vârsta} + \beta_2 \times \text{IMC} + \beta_3 \times \text{Activitate} \quad (5.11)$$

Exemplu numeric ipotetic - presupunem că, pe baza unui eșantion de 50 de pacienți, am obținut:

$$\text{Glicemie} = 60 + 0.5 \times \text{Vârsta} + 1.2 \times \text{IMC} - 4.0 \times \text{Activitate}$$

- **Interceptul (60)** → valoarea de bază a glicemiei pentru un pacient cu vârstă 0, IMC 0 și scor activitate 0 (doar o constantă de referință matematică).
- **Coeficientul pentru vârstă (0,5)** → fiecare an în plus crește glicemia cu **0,5 mg/dl**, dacă IMC și activitatea rămân constante.
- **Coeficientul pentru IMC (1,2)** → fiecare unitate de IMC crește glicemia cu **1,2 mg/dl**.
- **Coeficientul pentru activitate (-4,0)** → fiecare nivel suplimentar de activitate fizică scade glicemia cu **4 mg/dl**, la aceeași vârstă și același IMC.

 *Exemplu clinic* - un pacient de 50 ani, cu IMC = 30 și activitate = 2:

$$\text{Glicemie} = 60 + 0.5 \times 50 + 1.2 \times 30 - 4.0 \times 2 = 60 + 25 + 36 - 8 = 113$$

Interpretare: modelul estimează că acest pacient are o glicemie de **113 mg/dl**.


Analiza de supraviețuire

Această metodă se folosește atunci când interesul este legat de **timpul până la apariția unui eveniment** (deces, recidivă tumorală, complicație post-operatorie).

- **Curbele Kaplan–Meier** descriu proporția de pacienți care „supraviețuiesc” (nu prezintă evenimentul) la diferite momente în timp.

- **Modelul Cox (proporțional hazard)** evaluează influența mai multor factori asupra riscului de eveniment.

🕒 *Exemplu clinic:* compararea supraviețuirii pacienților oncologici în funcție de tratamentul administrat.



Analiza factorială și reducerea dimensionalității

Când datele includ foarte multe variabile, analiza factorială sau **analiza componentelor principale (PCA)** reduce numărul acestora la un set mai mic de factori, păstrând cât mai mult din informația inițială.

🕒 *Exemplu clinic:* într-un studiu de calitate a vieții, chestionarul are 50 de întrebări; analiza factorială poate reduce dimensiunile la câțiva factori majori (ex. funcționare fizică, stare emoțională, suport social).

Statistica clasică și instrumentele AI

Instrumentele moderne de inteligență artificială nu înlocuiesc statisticile clasice, ci le extind. Algoritmi precum rețelele neuronale sau arborii de decizie se bazează pe aceleași concepte fundamentale de variabilitate, corelație și

inferență, dar pot integra simultan un număr mult mai mare de variabile și volume de date imposibil de gestionat prin metodele tradiționale.

Exemple de instrumente AI deja în uz:

- ChatGPT, Gemini sau Copilot ca asistenți în analiza datelor și interpretarea rezultatelor.
- Algoritmi de învățare automată pentru predicția riscului de boli cardiovasculare sau pentru analiza imaginilor medicale.

Metodele statistice prezentate – de la analiza univariată la cea multivariată – rămân fundamentale pentru orice cercetător sau clinician. În prezent, acestea sunt completate de instrumente avansate de inteligență artificială, care pot integra simultan sute de variabile și volume masive de date (Big Data). Dacă statistica clasică răspunde la întrebarea „*există o diferență semnificativă?*”, AI încearcă să răspundă la „*ce se va întâmpla cu acest pacient?*”.

Totuși, utilizarea AI trebuie privită critic: modelele pot fi greu de interpretat („cutii negre”), sunt dependente de calitatea datelor de antrenare și pot genera erori sistematice dacă nu sunt validate riguros. De aceea, **îmbinarea statisticii clasice, transparente și validate, cu instrumentele AI, flexibile și predictive, este esențială pentru medicina digitală modernă.**

De reținut

- Analiza univariată descrie o singură variabilă prin indicatori de tendință centrală și dispersie.
- Analiza bivariată explorează relația dintre două variabile prin corelații, comparații de medii sau tabele de contingență.
- Analiza multivariată integrează mai mulți factori, permițând modele predictive complexe.
- Statistica clasică și AI sunt complementare: prima oferă validare și transparență, a doua – capacitate predictivă și integrarea Big Data.

Capitolul 6 – Prelucrarea biosemnalelor

6.1. Definiție și clasificarea biosemnalelor

Introducere

În capitolele anterioare am discutat despre date numerice și calitative și despre metodele statistice prin care acestea pot fi transformate în informații utile clinic. În mod tradițional, informațiile clinice se obțin fie prin **biomarkeri** – valori discrete, rezultate din analize de laborator (ex. glicemie, colesterol, enzime hepatice), fie prin **biosemnale** – variații continue ale unor mărimi fiziologice (ex. ECG, EEG, EMG). Ambele reflectă funcționarea organismului și pot fi utilizate pentru diagnostic și monitorizare.

Diferența esențială este că biomarkerii descriu „fotografii” punctuale ale stării biologice, în timp ce biosemnalele oferă o „înregistrare dinamică” a proceselor fiziologice. Integrarea celor două tipuri de date permite o înțelegere mai completă a stării de sănătate: de exemplu, combinația dintre nivelul troponinei (biomarker biochimic) și forma complexului QRS pe ECG (biosemnal electric) oferă informații decisive în diagnosticul infarctului miocardic.

Monitorizarea ritmului cardiac, analiza activității cerebrale sau măsurarea fluxului respirator sunt alte câteva exemple de situații în care datele brute se prezintă sub forma unor semnale, ce trebuie achiziționate, prelucrate și interpretate pentru a deveni informații clinice.

Definiție

Un **biosemnal** reprezintă orice variație măsurabilă, în timp sau spațiu, a unei mărimi fizice sau chimice generate de organism. Biosemnalele transmit informații despre starea funcțională a organelor și sistemelor biologice și sunt fundamentale în diagnostic și monitorizare.

Etapele de prelucrare a unui biosemnal

Un biosemnal, așa cum este generat de organism, reprezintă doar o variație brută a unei mărimi fiziologice. Pentru a deveni informație utilă clinic, acesta trebuie supus unui proces de prelucrare în mai multe etape. Primul pas este **achiziția semnalului**, realizată prin senzori sau electrozi care captează

fenomenul biologic și îl transformă într-un semnal electric. Ulterior, semnalul este **digitizat**, pentru a putea fi stocat și procesat pe calculator.

Odată obținut semnalul digital, se aplică diverse **prelucrări** menite să reducă zgomotele, să corecteze artefactele și să pună în evidență aspectele relevante. Din **semnalul transformat** se realizează apoi **selecția parametrilor**, adică alegerea acelor caracteristici care descriu cel mai bine fenomenul studiat: amplitudini, durate, frecvențe sau forme de undă.

În etapa finală, **parametrii** extrași sunt supuși unei **clasificări** – proces care poate fi realizat prin reguli statistice sau prin algoritmi de inteligență artificială. Rezultatul este un **semnal interpretat**, capabil să ofere medicului informații obiective pentru diagnostic, monitorizare sau decizie terapeutică.

Clasificarea biosemnalelor

Biosemnalele pot fi clasificate din mai multe perspective:

1. După natură

- **Semnale electrice** – rezultă din activitatea bioelectrică a celulelor și țesuturilor: ECG, EEG, EMG (electromiogramă).
- **Semnale ne-electrice** – includ variații de presiune (tensiune arterială), flux (spirometrie), concentrații biochimice (glicemie), temperatură sau mișcare (accelerometrie).

2. După evoluție în timp

- **Semnale periodice** – se repetă regulat, cum este ECG-ul, unde fiecare ciclu cardiac generează o undă asemănătoare.
- **Semnale neperiodice** – nu urmează un tipar fix, cum este EEG-ul, unde activitatea cerebrală are o variație complexă, aparent aleatorie.

3. După sursa generatoare

- **Biosemnale proprii** – generate direct de organism:
 - mecanice (fonocardiografie – zgomote cardiace, spirometrie – flux respirator),
 - termice (măsurarea temperaturii),
 - metabolice (niveluri de glucoză, lactat),
 - electrice (ECG, EEG, EMG).

- **Biosemnale mediate** – obținute prin interacțiunea organismului cu un stimul extern, pe care organismul îl modulează:
 - radiații ionizante (radiografie, CT),
 - radiații neionizante (RMN, ecografie cu ultrasunete),
 - unde mecanice sau câmpuri electromagnetice,
 - curenți electrici aplicați extern (impedanța bioelectrică, pletismografie).

6.2. Sistemele de achiziție a biosemnalelor

Un biosemnal nu poate fi utilizat direct, ci trebuie captat, amplificat, filtrat și convertit într-o formă digitală care să poată fi prelucrată de calculator. Toate aceste etape sunt realizate de **sistemele de achiziție**, care constituie puntea dintre fenomenul biologic și interpretarea clinică.

Componentele principale ale unui sistem de achiziție:

1. **Sursa biologică** – procesul fiziologic care generează semnalul (de exemplu, activitatea electrică a inimii).
2. **Traductorul sau senzorul** – transformă fenomenul biologic într-un semnal electric măsurabil (electrozi pentru ECG/EEG, microfoane pentru fonocardiografie, senzori optici pentru fotopletismografie).
3. **Circuitul de condiționare** – include **amplificarea** (pentru semnale foarte slabe, cum este EEG-ul), **filtrarea** (pentru eliminarea zgomotului de rețea sau mișcare) și adaptarea semnalului la nivelurile necesare conversiei.
4. **Convertorul analog–digital (A/D)** – transformă semnalul continuu într-o secvență de valori numerice discrete, prin eșantionare și cuantizare.
5. **Sistemul de procesare și stocare** – calculatorul sau dispozitivul dedicat care preia semnalul digital, îl prelucrează și îl salvează pentru analiză ulterioară.
6. **Interfața de afișare și interpretare** – monitor, aplicații software, instrumente de vizualizare care oferă medicului o reprezentare clară și relevantă.






Fig. 6.1 Schema bloc de achiziție a semnalului EEG

Un sistem de achiziție a biosemnalelor trebuie să fie suficient de sensibil pentru a detecta semnale slabe, dar și suficient de robust pentru a elimina zgomotele și artefactele. Fiecare etapă, de la senzor până la conversia A/D, contribuie la calitatea finală a semnalului interpretat.

6.3. Conversia analog–numerică a biosemnalelor

Semnalele biologice, așa cum sunt generate de organism, sunt **continue**: valorile lor se modifică permanent în timp și pot lua orice valoare într-un anumit interval. Un calculator nu poate însă lucra cu semnale continue, ci doar cu șiruri de **valori numerice discrete**. Procesul prin care transformăm semnalul analogic într-un șir de valori digitale se numește **conversie analog–numerică (A/N)**.

Această conversie are două etape fundamentale: **eșantionarea** și **cuantizarea**.

Eșantionarea

Eșantionarea constă în prelevarea valorii semnalului la intervale regulate de timp. Intervalul dintre două măsurători se numește **perioada de eşantionare** (T_e), iar inversul ei se numește **frecvența de eşantionare** (6.1).

- Cu cât T_e este mai mic (adică frecvența f_e este mai mare), cu atât avem mai multe valori și semnalul digital se apropie mai mult de forma originală. Nu are însă rost să creștem f_e foarte mult, întrucât numărul de valori generate crește inutil, fără beneficii directe în privința semnalului reconstituit.
- Dacă însă f_e este prea mică, semnalul digitalizat va pierde informații importante.

$$f_e = 1/T_e \quad (6.1)$$

Acest fenomen este explicat de **Teorema Shannon–Nyquist**, care spune că pentru a reconstrui corect un semnal, trebuie să alegem o frecvență de eșantionare de cel puțin **dublul frecvenței maxime** conținute în semnal:

$$f_e \geq 2 \times f_{\max} \quad (6.2)$$

 *Exemplu:* ECG are componente utile până la aproximativ 100 Hz. Prin urmare, frecvența minimă de eșantionare este 200 Hz. În practică, se folosesc 250–500 Hz pentru siguranță.

Dacă această condiție nu este respectată, apare fenomenul de **aliasing**: semnalul digital conține componente false, deformându-se grav forma de undă. În aparatele medicale, aliasingul este prevenit prin **filtre anti-aliasing**, care elimină frecvențele nedorite înainte de conversie.




Fig. 6.2. Digitizarea unui semnal analogic

Cuantizarea


După eșantionare, fiecare valoare obținută este încă „continuă”, în sensul că poate avea o infinitate de valori posibile între maxim și minim. Pentru a fi stocată în calculator, ea trebuie adusă la cel mai apropiat nivel disponibil, proces numit **cuantizare**.

Unitatea minimă de diferență între două valori posibile se numește **quantă (q) de amplitudine**. Ea depinde de intervalul de variație al semnalului și de numărul de biți cu care este codificat:

$$q = \frac{A_{\max} - A_{\min}}{2^n} \quad (6.3)$$

unde:

- $A_{\max}$, $A_{\min}$ = valorile extreme ale semnalului (amplitudinea maximă și minimă),
- n = numărul de biți folosiți pentru reprezentare,
- $N=2^n$ = numărul total de niveluri disponibile în intervalul $A_{\max} - A_{\min}$.



Eroarea de cuantizare este diferența dintre valoarea reală și valoarea rotunjită la cel mai apropiat nivel; ea este de maximum $\pm q/2$.

Exemplu: Dacă avem un semnal cu amplitudine maximă de 10 V și un convertor pe 8 biți, numărul de niveluri este $N = 2^8 = 256$. Astfel:

$$q = 10/256 \approx 0,039 \text{ V}$$

Cu un convertor pe 12 biți:

$$q = 10/4096 \approx 0,0024 \text{ V}$$

→ rezoluția este de aproximativ 16 ori mai bună, iar semnalul digital rezultat este mult mai fidel.

Time (hh:mm:ss.mmm dd/mm/yyyy)	Date	F1-F7 (uV)	F7-T7 (uV)	T7-P7 (uV)	P7-O1 (uV)	F1-F3 (uV)	F3-C3 (uV)	C3-P3 (uV)	P3-O1 (uV)	FP2-F4 (uV)	F4-C4 (uV)	C4-P4 (uV)	P4-O2 (uV)	FP2-F8 (uV)	F8-O2 (uV)
[11:42:54.000 06/11/2076]		-145.739													
[11:42:54.004 06/11/2076]		0.391	0.391	0.391	0.391	0.391	0.391	0.391	0.391	0.391	0.391	0.391	0.391	0.391	0.391
[11:42:54.008 06/11/2076]		0.391	0.391	0.391	0.391	0.391	0.391	0.391	0.391	0.391	0.391	0.391	0.391	0.391	0.391
[11:42:54.012 06/11/2076]		0.391	0.781	0.391	0.781	0.391	0.391	0.391	0.391	0.391	0.391	0.391	-1.172	-0.391	1.563
[11:42:54.016 06/11/2076]		0.391	0.391	0.391	0.000	0.391	0.391	0.391	0.391	0.391	0.391	0.391	0.781	0.000	0.391
[11:42:54.020 06/11/2076]		1.172	-1.172	1.563	-1.172	0.391	0.391	0.781	-0.781	1.563	0.391	0.781	7.814	4.689	-5.861
[11:42:54.023 06/11/2076]		0.781	-3.516	3.126	0.000	-0.391	0.781	0.391	0.000	1.954	-0.391	0.391	7.424	4.689	-3.516
[11:42:54.027 06/11/2076]		-1.563	-0.781	0.391	1.954	-1.172	0.391	-0.781	1.954	-0.781	0.000	-0.391	-5.861	-5.470	7.814
[11:42:54.031 06/11/2076]		-1.172	3.126	-3.126	1.172	-0.391	-0.781	0.000	1.563	-1.563	0.391	0.391	-9.377	-7.424	7.814
[11:42:54.035 06/11/2076]		3.126	1.563	-1.172	-1.172	2.344	-0.391	1.172	-1.563	3.126	0.391	1.172	7.814	7.814	-10.117
[11:42:54.039 06/11/2076]		4.298	-5.470	3.907	-5.079	0.781	0.391	-3.516	2.735	-0.391	1.172	28.523	13.675	-18.523	13.675
[11:42:54.043 06/11/2076]		3.907	-21.880	13.284	-14.457	-10.159	-1.563	1.563	-7.424	3.126	-4.298	2.344	61.343	16.801	-34.298
[11:42:54.047 06/11/2076]		2.344	-42.198	24.225	-12.894	-16.410	-1.172	-0.391	-9.377	17.582	-9.768	-0.391	80.879	38.291	-52.735
[11:42:54.051 06/11/2076]		-3.907	-51.575	19.536	-6.252	-28.132	-2.735	-8.205	-1.954	15.629	-15.238	-4.298	69.158	20.317	-32.617
[11:42:54.055 06/11/2076]		-1.563	-39.463	3.516	-5.861	-22.271	-7.424	-11.331	-1.954	5.470	-14.066	-5.470	55.092	-0.781	-24.298
[11:42:54.059 06/11/2076]		3.907	-27.741	-5.470	-9.768	-11.722	-7.814	-14.847	-3.516	1.954	-10.940	-5.861	58.999	4.689	-42.198
[11:42:54.063 06/11/2076]		9.377	-15.629	-10.549	-16.020	-1.954	-6.252	-18.364	-5.861	-2.735	-8.205	-7.424	62.515	3.907	-39.463
[11:42:54.067 06/11/2076]		11.331	-12.112	-5.861	-22.271	2.344	-1.563	-19.536	-8.987	-25.397	-0.391	-7.424	62.906	-16.410	-18.523
[11:42:54.070 06/11/2076]		5.079	-27.741	5.470	-21.490	-7.814	3.126	-20.317	-14.066	-2.735	2.344	-10.549	55.482	13.284	-28.523
[11:42:54.074 06/11/2076]		1.172	-38.291	6.252	-12.503	-16.410	8.205	-19.536	-15.238	15.629	0.391	-14.457	44.933	34.774	-16.801
[11:42:54.078 06/11/2076]		4.689	-25.788	0.391	-13.284	-17.582	16.801	-16.801	-16.020	24.615	1.563	-14.847	44.151	43.370	-18.523
[11:42:54.082 06/11/2076]		11.331	-20.708	11.331	-13.675	-21.099	20.708	-16.020	-18.364	29.695	-1.172	-17.582	48.059	51.966	-44.570
[11:42:54.086 06/11/2076]		12.894	0.391	-9.377	-19.145	-17.582	26.960	-9.768	-13.675	30.085	-1.954	-20.708	36.728	48.840	-31.284
[11:42:54.090 06/11/2076]		16.020	16.020	-11.722	-16.020	-15.629	32.821	-5.470	-6.642	21.099	2.344	-24.615	26.569	33.211	-17.582
[11:42:54.094 06/11/2076]		21.880	1.563	-7.033	-12.894	-13.675	36.728	-8.987	-9.768	17.582	3.126	-31.258	28.523	39.072	-35.563
[11:42:54.098 06/11/2076]		22.662	-13.675	11.331	-11.331	-10.159	44.151	-13.284	-10.940	22.662	4.298	-35.563	30.085	51.966	-39.463
[11:42:54.102 06/11/2076]		19.145	-16.020	10.940	-5.861	-8.205	43.370	-17.582	-8.205	22.271	3.126	-39.463	14.457	42.589	-24.617
[11:42:54.106 06/11/2076]		14.847	-12.503	0.391	-6.252	-13.284	34.774	-18.755	-5.861	17.582	-1.954	-43.370	7.814	30.867	-29.617
[11:42:54.109 06/11/2076]		11.331	-7.424	-1.563	-0.781	-9.377	29.304	-15.629	-2.344	24.615	-5.470	-47.277	14.847	39.072	-32.617
[11:42:54.113 06/11/2076]		1.954	-2.344	-7.033	1.954	-14.066	16.801	-8.987	1.172	32.430	-8.205	-53.919	4.689	42.589	-18.523
[11:42:54.117 06/11/2076]		-5.861	-1.172	-12.503	8.987	-21.880	5.470	-8.205	12.894	28.913	-18.364	-60.562	3.907	28.913	-19.145
[11:42:54.121 06/11/2076]		-0.781	-10.159	-1.563	3.516	-14.847	12.894	-14.457	6.252	31.648	-26.960	-57.045	3.907	35.946	-39.463
[11:42:54.125 06/11/2076]		0.391	-21.099	0.391	5.861	-10.940	12.894	-20.708	5.079	33.211	-32.430	-58.217	-1.172	40.635	-39.463
[11:42:54.129 06/11/2076]		-6.642	-36.337	11.331	5.861	-14.847	10.940	-25.006	3.907	25.397	-35.946	-59.780	-9.377	33.602	-37.582
[11:42:54.133 06/11/2076]		-8.205	-46.496	15.629	4.689	-16.410	11.722	-26.960	-1.563	21.490	-38.291	-62.125	-9.768	28.132	-45.735

Fig. 6.3 Semnal digitalizat, înainte de reprezentarea grafică

Caracteristicile convertoarelor A/D

Un convertor A/D este caracterizat prin mai mulți parametri importanți:

- **Frecvența maximă de eșantionare** – determină cât de rapid poate fi achiziționat semnalul. Valori obișnuite: 100-1000 Hz

- **Numărul de biți** – stabilește precizia cu care este reprezentată amplitudinea. Valori obișnuite ("cuvinte" binare cu lungimea de): 8, 10, 12, 16 biți
- **Lățimea de bandă** – domeniul de frecvențe pentru care funcționează corect – specific fiecărui tip de semnal.
- **Multiplexarea** – permite achiziția simultană de la mai multe canale (ex. 12-16 canale ECG), comutând rapid între ele.

Considerații practice

- Dacă alegem o frecvență de eșantionare prea mică → pierdem detalii importante (aliasing).
- Dacă alegem un număr de biți prea mic → semnalul devine „granulat”, pierzând precizie.
- În aparatele medicale moderne, se folosesc convertoare de **minim 12 biți** și frecvențe de eșantionare adaptate fiecărui tip de semnal (de ex. 500 Hz pentru ECG, 256 Hz pentru EEG).
- În practica medicală, același convertor analog-digital (CAN) este folosit pentru mai multe canale, de exemplu pentru mai multe perechi de electrozi la EEG sau pentru combinația ECG–SpO₂–TA într-un monitor. Conversia nu se face simultan, ci prin **multiplexare**: CAN-ul comută foarte rapid între canale, preluând pe rând fiecare semnal, astfel încât pentru utilizator datele apar „în paralel”. Acest mecanism reduce costurile și complexitatea sistemului, dar necesită o frecvență de eșantionare suficient de mare pentru a acoperi toate canalele fără pierderi de informație.

Conversia A/N transformă așadar biosemnalele în șiruri de valori numerice. Alegerea corectă a frecvenței de eșantionare și a numărului de biți este esențială pentru fidelitatea datelor și pentru calitatea diagnosticului bazat pe ele.

6.4. Reprezentarea frecvențială a biosemnalelor

Semnalele biologice pot fi analizate în două moduri:

- în **domeniul temporal**, unde observăm variația amplitudinii în timp (ex. forma unei ECG) - $Ampl = f(timp)$
- în **domeniul frecvențial**, unde observăm cum energia semnalului se distribuie pe componente de frecvență - $Ampl = f(frecv)$

Orice semnal complex poate fi considerat ca o **sumă de semnale sinusoidale simple** (armonici) de frecvențe, amplitudini și faze diferite.

Transformata Fourier „traduce” semnalul din domeniul timpului în domeniul frecvenței. În acest mod, un semnal aparent haotic poate fi analizat prin componentele sale spectrale, evidențiind structuri, ritmuri sau anomalii invizibile în reprezentarea temporală.

Reprezentarea frecvențială permite evidențierea caracteristicilor ascunse în semnalul temporal:

- în **EEG**, benzile α (8–13 Hz), β (13–30 Hz), θ (4–8 Hz) și δ (0,5–4 Hz) sunt asociate cu stări diferite de activitate cerebrală;
- în **fonocardiografie**, analiza spectrală evidențiază zgomote patologice (murmure) în spectrul audio;
- în **EMG**, spectrul semnalului muscular permite detectarea oboselii musculare prin deplasarea frecvenței medii.




Fig. 6.4 Analiza Fourier a unor unde sinusoidale

Spectrul de amplitudine și spectrul de putere

După ce un semnal a fost transformat în domeniul frecvenței (prin transformata Fourier), putem reprezenta rezultatul în mai multe moduri, în funcție de scopul analizei.

Spectrul de amplitudine arată amplitudinea fiecărei componente sinusoidale în funcție de frecvență. Este util pentru analiza **forme** **semnalului** și pentru identificarea frecvențelor dominante. Se folosește frecvent în analiza semnalelor **EMG** sau **fonocardiografice**, unde amplitudinile relative indică intensitatea vibrațiilor sau a contracțiilor.

Spectrul de putere (Power Spectrum) arată **energia** semnalului distribuită pe frecvențe. Se obține prin pătratul amplitudinilor și este mai potrivit pentru semnale aleatorii, precum **EEG**, unde amplitudinea instantanee nu este stabilă, dar distribuția de putere pe benzi oferă informații relevante despre activitatea cerebrală.




Fig. 6.5 Reprezentarea temporală (sus) și spectrul putere (jos)



Exemplu clinic:

- În EEG, puterea relativă din banda α (8–13 Hz) crește în stările de relaxare, iar cea din banda β (>13 Hz) în stările de activitate mentală.
- În EMG, spectrul de putere se deplasează spre frecvențe mai joase odată cu **oboseala musculară**, ceea ce permite evaluarea obiectivă a performanței musculare.

6.5. Filtrarea semnalului

În practica medicală, biosemnalele sunt rareori pure. Chiar și într-un laborator controlat, apar interferențe provenite din mediul electric, mișcarea pacientului sau contactul imperfect al senzorilor.

Definiție

Filtrarea semnalului reprezintă procesul prin care se elimină componentele nedorite (zgomote, artefacte) și se păstrează informația relevantă din semnalul biologic.

Filtrul este un sistem electronic sau software care **modifică amplitudinea sau faza** componentelor de frecvență ale semnalului, în funcție de frecvență. Cu alte cuvinte, un filtru permite trecerea anumitor frecvențe și atenuează altele. Filtrarea realizează o „curățare” a semnalului biologic. Alegerea tipului de filtru și a frecvențelor de tăiere trebuie făcută cu grijă, astfel încât să se elimine doar zgomotul, nu și informația fiziologică utilă.

Sursele și clasificarea zgomotelor

Zgomotul reprezintă orice semnal care se suprapune peste semnalul biologic și care nu conține informație utilă.

Sursele de zgomot pot fi:

1. **Zgomote externe (electromagnetice)**

- **Interferența de la rețeaua electrică (50 Hz)** – cea mai frecventă cauză în ECG și EEG;
- Câmpuri electromagnetice de la alte echipamente medicale (monitoare, defibrilatoare, pompe).

2. **Zgomote interne (fiziologice)**

- Activitatea musculară (artefact EMG) care se suprapune peste EEG;
- Respirația sau mișcările pacientului (modifică potențialele electrice).

3. **Zgomote datorate echipamentului**

- Contact imperfect al electrozilor;
- Drift termic al amplificatorilor;
- Limitări ale conversiei A/D.

Tipuri principale de filtre

• **Filtru trece-jos (Low-pass filter)**

- Lasă să treacă frecvențele joase și atenuează frecvențele înalte.
- Util pentru eliminarea zgomotelor de înaltă frecvență.
- *Exemplu:* în ECG, filtrul trece-jos elimină frecvențele de peste 100 Hz.

• **Filtru trece-sus (High-pass filter)**

- Lasă să treacă frecvențele înalte, eliminând componentele lente.
- *Exemplu:* în EEG, filtrele trece-sus elimină variațiile lente datorate mișcării ochilor sau respirației (sub 0,5 Hz).

• **Filtru trece-bandă (Band-pass filter)**

- Lasă să treacă doar o anumită bandă de frecvențe (între f_{min_min} și f_{max_max}).

- *Exemplu:* în EEG, filtrul 0,5–45 Hz păstrează componentele utile, eliminând driftul și zgomotele înalte.
- **Filtru oprește-bandă (Band-stop / Notch filter)**
 - Elimină o bandă îngustă de frecvențe, păstrând restul spectrului.
 - *Exemplu:* filtrul **Notch de 50 Hz** este folosit aproape universal pentru a elimina interferența rețelei electrice.

Clasificarea filtrelor după implementare

- **Filtre analogice:** realizate prin circuite electronice (rezistențe, condensatori, amplificatoare operaționale); sunt utilizate în etapele de preprocesare ale semnalului, înainte de conversia A/D.
- **Filtre digitale:** implementate software, după conversie. Pot avea o precizie mult mai mare și sunt adaptabile. Cele mai utilizate tipuri sunt:





Fig. 6.6 Filtru digital: $y(n)=x(n)+x(n-1)$

Importanță clinică

Filtrarea corectă este esențială pentru acuratețea diagnosticului:

- un **filtru prea agresiv** poate elimina componente utile ale semnalului (de exemplu undele P sau T din ECG),
- un **filtru insuficient** lasă zgomote care pot fi interpretate greșit drept anomalii patologice.

De aceea, în practica medicală modernă, sistemele de achiziție combină filtre **analogice hardware** (pentru zgomote de bază) și **filtre digitale software** (pentru rafinarea semnalului).

6.6. Analiza semnalelor periodice – semnalul EKG

Semnalele **periodice** sunt acelea care se repetă în timp, având o structură ciclică stabilă. Activitatea electrică a inimii este un exemplu tipic de semnal periodic, ușor de observat prin **electrocardiogramă (EKG/ECG)**.

ECG-ul reflectă succesiunea coordonată a potențialelor electrice generate de miocard în timpul fiecărui ciclu cardiac. Prin analizarea formei de undă, putem deduce atât parametri fiziologici (ritm, frecvență), cât și semne patologice (ischemie, aritmii, tulburări de conducere).




Fig. 6.7. Culegerea semnalului ECG - Rasel Hossain Md CC-BY-SA-4.0

Structura unui ciclu ECG

Un ciclu ECG complet cuprinde mai multe unde și segmente caracteristice (Fig. 6.8):

- **Unda P** – depolarizarea atrială (conducerea impulsului în atri).
- **Complexul QRS** – depolarizarea ventriculilor; cea mai amplă componentă a semnalului.
- **Unda T** – repolarizarea ventriculară.
- **Intervalele PQ, QT și RR** – măsoară timpii de conducere și ritmicitatea bătăilor inimii.

Semnalul EKG este relativ periodic (quasi-periodic), repetându-se la fiecare contracție cardiacă, cu o **perioadă medie** de aproximativ **0,8 s** (corespunzător unei frecvențe cardiace de 75 bpm). $f_c = 1/T_c = 1/0,8 \text{ s} \approx 1,25 \text{ Hz}$

Analiza temporală

În domeniul timpului, analiza EKG se bazează pe:

- **amplitudini** (ex. unda R $\approx 1 \text{ mV}$),
- **durate** (complex QRS $\approx 80\text{--}100 \text{ ms}$),
- **intervale** (RR, PQ, QT),
- **forma de undă** (identificarea deviațiilor patologice).




Fig. 6.8 Diagrama ritmului sinusal pentru o inimă umană, așa cum apare pe ECG

Pentru o analiză corectă, semnalul este prelucrat prin:

- filtrare trece-sus (pentru driftul de bază),
- filtrare Notch (50 Hz),
- eventual filtrare trece-jos (pentru zgomot EMG).

Rezultatul este un semnal curat, din care se pot extrage parametrii de diagnostic (ritm sinusal, extrasistole, fibrilație etc.).




Figura 6.9. Semnal ECG înainte și după filtrare, cu detecția undelor R

Fig. 6.9 arată semnalul ECG înainte și după aplicarea unui filtru band-pass (0,5–45 Hz). În semnalul brut se observă driftul de bază (componentă joasă frecvență) și zgomot de înaltă frecvență; filtrarea păstrează componentele utile ale ECG și permite detectarea sistematică a vârfurilor R (marcate).

Analiza frecvențială

Deși ECG-ul este analizat în principal în domeniul timpului, analiza **frecvențială** oferă informații suplimentare, în special pentru evaluarea **variabilității ritmului cardiac (HRV)**.

Spectrul ECG prezintă o componentă dominantă în jurul frecvenței cardiace (≈ 1 Hz) și armonici asociate (2–5 Hz).



Exemple clinice și interpretare

- **Tahicardie:** reducerea perioadei RR $\rightarrow$ creșterea frecvenței dominante (peste 1,5 Hz).
- **Bradicardie:** creșterea perioadei RR $\rightarrow$ frecvență dominantă sub 1 Hz.
- **Fibrilația atrială:** absența undei P, variație neregulată a intervalului RR $\rightarrow$ spectru mai „dispersat”.
- **Ischemie miocardică:** modificarea amplitudinii sau polarității undei T.

Fazele prelucrării semnalului ECG

Prelucrarea unui EKG clinic începe cu definirea perioadei cardiace: în plan fiziologic putem vorbi despre **perioada funcțională (P–P)**, care reflectă ritmul generat la nivelul atriilor, însă în practică, pentru că vârful R este cel mai ușor

de detectat în majoritatea înregistrărilor, se utilizează frecvent **perioada detectabilă R–R**. Măsurarea intervalelor R–R permite calculul **frecvenței cardiace** și segmentarea în cicluri cardiace, operație indispensabilă pentru multe analize ulterioare. Detectarea vârfurilor R se poate realiza simplu prin metoda **intersecției de nivel** (threshold crossing) — adică marcând trecerile semnalului printr-un prag fix sau adaptiv — dar pentru robustețe în prezența zgomotului se folosesc algoritmi dedicați (de exemplu variante ale algoritmului Pan–Tompkins) care combină filtrare, derivare și operații nonlinear-e pentru a localiza cu precizie complexe QRS.

Odată marcate evenimentele R, urmează **eliminarea artefactelor** și **netezirea semnalului**. În practică se aplică o combinație de filtre: un filtru trece-sus pentru eliminarea driftului de bază (care apare din mișcări sau respirație), un filtru notch pentru a elimina interferența rețelei electrice (50/60 Hz) și, dacă e cazul, un filtru trece-jos pentru atenuarea zgomotelor de înaltă frecvență (ex. zgomot EMG). După filtrare se poate aplica o netezire locală sau o mediere care reduce variațiile nebiologice.




Fig. 6.10 Reproducerea semnalelor ECG din date brute (<http://biostatmatt.com>)

Următoarea etapă este **tipificarea complexului QRS și analiza segmentului ST–T**. După izolarea fiecărui QRS se măsoară *durata* (lățimea), *amplitudinea* și se evaluează *morfologia* pentru a detecta blocuri de ramură, deviații de ax sau complexuri patologice. Segmentul ST și unda T se analizează prin raportare la linia de bază obținută anterior prin filtrare; orice elevație sau depresie semnificativă a ST, precum și inversiunea sau aplatizarea undei T, sunt semne importante pentru diagnosticul ischemiei sau infarctului miocardic, motiv pentru care estimarea corectă a liniei de repaus este esențială înainte de a trage concluzii.

Detecția undei P este, de regulă, mai dificilă decât detectarea R, deoarece P are amplitudine mică și poate fi mascată de zgomote sau de complexul QRS. Pentru identificarea fiabilă a undei P se utilizează o combinație de tehnici: amplificare selectivă a benzii frecvențiale utile, template matching (compararea cu un model de undă P) sau metode de analiză în domeniul timp-frecvență (de exemplu wavelet), care scot în evidență structurile de mică amplitudine. Detecția P este esențială când vrem să diferențiem tahicardiile supraventriculare de cele ventriculare ori să evaluăm conducerea atrioventriculară.

După extragerea și validarea undelor și intervalelor se **selectează ciclul „tipic”** pentru analize mai fine — un ciclu lipsit de artefacte, cu un QRS clar — care poate servi drept template pentru aliniere și medierea mai multor cicluri (utile la calculul potențialelor evocate sau la analiza HRV).

Pe lângă **analiza ECG standard** (ritm, frecvență, durate PR/QRS/QT, amplitudini P/R/T și modificări ST), există **analize avansate** folosite în practica electrofiziologică și cardiologică:

- vectocardiografia (reconstruirea vectorială a activității electrice în spațiu),
- mapping-ul cardiac pentru localizarea focarelor aritmogene,
- analiza potențialelor tardive
- clasificarea automată a aritmiilor.

Din punct de vedere practic, pentru înregistrări diagnostice detaliate se recomandă rate de eșantionare suficient de mari (de exemplu ≥ 500 Hz pentru măsurători precise ale pantei și duratei QRS) și convertori A/D cu rezoluție minimă de 12 biți (ideal 14–16 biți pentru aplicații avansate). Filtrarea trebuie

să combine etape analogice (anti-aliasing înainte de A/D) cu filtrare digitală ulterioară (FIR) și orice algoritm automat de interpretare trebuie validat clinic și verificat vizual înainte de a fi folosit în decizii pacient-centrice.

6.7 Analiza semnalelor neperiodice- EEG

Activitatea electrică cerebrală înregistrată la scalp — EEG — este unul dintre cele mai convingătoare exemple de biosemnal **neperiodic** și **non-staționar**: forma sa variază continuu în timp, influențată de starea de veghe, somn, stimulii senzoriali și procesele cognitive sau patologice. Spre deosebire de ECG, unde ciclurile se repetă relativ regulat, EEG-ul este un amestec de ritmuri tranzitorii, oscilații persistente în benzi de frecvență și episoade izolate (de exemplu spike-uri epileptice). Această natură dinamică impune o abordare analitică care combină atenția la calitatea achiziției, preprocesare riguroasă și metode atât în domeniul frecvențial, cât și în cel timp-frecvență.

Încă din momentul montării electrozilor se pune o problemă practică importantă: configurația electrodială (de ex. sistemul 10–20) și tipul referinței influențează puternic semnalul. Alegerea referinței (mastoidă, medie, bipolară) determină ce anume observăm pe trasee și va condiționa analizele ulterioare. De aceea, înainte de orice procesare trebuie să verificăm conectarea electrozilor, impedanțele și etichetarea evenimentelor; calitatea datelor colectate este baza interpretării valabile clinic.

Preprocesarea EEG începe cu filtrarea: se aplică filtre hardware anti-aliasing înaintea conversiei A/N și filtre digitale ulterioare (band-pass, nota: 0,5–70 Hz este o alegere uzuală în clinică; notch 50/60 Hz pentru eliminarea rețelei). Filtrarea nu este doar o operație tehnică — este un compromis: trebuie eliminate componentele care nu aduc informație fiziologică (driftul de bază, interferențele de rețea, zgomotul EMG) fără a suprima sau deforma semnalele de interes. Urmează operații de re-referențiere (de multe ori referința medie reduce artefactele comune) și detectare/înlăturare de artefacte. Artefactele produse de clipiri oculare (EOG), mișcări sau activitate musculară (EMG) pot domina înregistrarea, iar metodele moderne — de la regresie simplă la ICA (Independent Component Analysis) sau wavelet denoising — permit izolarea și îndepărtarea lor, dar necesită verificare vizuală atentă pentru a nu elimina componente neurologice valide.

Din momentul în care avem un semnal curat începe analiza propriu-zisă. O abordare de bază este reprezentarea frecvențială: transformata Fourier (sau FFT pentru semnale discrete) spune cum se distribuie energia semnalului în frecvență. Pentru EEG aceasta înseamnă măsurarea puterii în benzile clasice — δ , θ , α , β , γ — care se corelează cu stări funcționale (de ex. banda α asociată relaxării cu ochii închiși). Practic, în loc să privim variația amplitudinii în timp, privim „câtă energie” există în fiecare bandă: aceasta este esența Power Spectral Density (PSD) și a metricilor derivate (putere absolută, putere relativă, rapoarte între benzi).




Fig. 6.11. Benzile de frecvență ale undelor cerebrale: delta, theta, alfa, beta și gamma.

Deoarece EEG este adesea non-staționar, analiza pur Fourier pe toată înregistrarea pierde informații despre dinamica temporală. Pentru a urmări cum se schimbă spectrul în timp folosim metode timp-frecvență: STFT (spectrograma) oferă o imagine a evoluției spectrale pe ferestre scurte, iar transformata wavelet aduce o flexibilitate mai mare — rezoluție fină la frecvențe înalte și rezoluție temporală mai bună la frecvențe joase, ideală pentru detectarea evenimentelor tranzitorii precum spike-urile epileptice. Aceste instrumente permit, de exemplu, vizualizarea apariției unei crize ca o creștere bruscă a puterii într-o anumită bandă și momentul său exact.

Un capitol important îl constituie potențialele evocate (ERP), care sunt semnale de mică amplitudine legate de un eveniment-stimulus. Prin segmentare (epoching) sincronizată pe stimulus și ulterior mediere (averaging) a multor epoci, semnalele legate de procesarea senzorială sau cognitivă (de ex.

N100, P300) ies din zgomotul de fond. ERP-urile sunt instrumente puternice în cercetare și în anumite investigații clinice, dar necesită atenție sporită la controlul artefactelor și la consistența paradigmei stimulului.

Pentru înțelegerea interacțiunilor cerebrale nu este suficientă analiza locală — trebuie să analizăm și **conectivitatea**. Măsuri precum coerența sau phase-locking value (PLV) cuantifică sincronizarea între două regiuni în anumite benzi de frecvență, iar abordările de tip rețea (analiză grafurilor) permit identificarea hub-urilor și a modularității rețelelor cerebrale. Aceste analize au aplicații clinice în localizarea focarelor epileptice sau în studiul bolilor neurodegenerative care alterează topologia rețelelor cerebrale.

Un pas avansat este încercarea de localizare a sursei — problema inversă: pornind de la potențialele scalpale estimăm distribuția activității corticale. Aceasta necesită un model geometric al capului și constrângeri matematice (regularizare); metode precum dipole fitting, LORETA sau beamforming oferă estimări utile în planificarea intervențiilor chirurgicale pentru epilepsie sau în cercetare funcțională, dar nu sunt lipsite de incertitudini și cer bune date de intrare.

Din punct de vedere clinic, analiza EEG are numeroase aplicații: detecția automată a crizelor și spike-urilor în epilepsie, monitorizarea continuă pentru convulsii non-convulsive în secțiunile critice, clasificarea etapelor somnului, evaluarea profunzimii anesteziei și dezvoltarea de interfețe creier-calculator (BCI) pentru pacienți cu dizabilități motorii. Metodele automate bazate pe machine learning pot accelera detectarea și clasificarea, dar succesul lor depinde crucial de calitatea și eticheta seturilor de antrenare și necesită validare clinică riguroasă.

Pentru studenți, concluzia practică este simplă: EEG oferă informații valoroase, dar extractul util depinde de proceduri corecte de achiziție și de preprocesare atentă. În practică, începeți prin a verifica impedanțele și montajul electrozilor, folosiți filtre adecvate și familiarizați-vă cu identificarea artefactelor uzuale. Instrumentele automate sunt utile, dar niciodată nu înlocuiesc verificarea vizuală și interpretarea clinică.

De reținut

Biosemnalele reflectă activitatea fiziologică a organismului și pot fi analizate doar dacă sunt corect achiziționate și prelucrate. Procesul începe cu transformarea semnalului biologic în semnal electric, urmată de amplificare, filtrare și conversie analog–numerică prin eșantionare și cuantizare.

Analiza frecvențială, bazată pe transformata Fourier, dezvăluie structura spectrală a semnalului, iar filtrarea elimină zgomotele și artefactele. Semnalele periodice, precum ECG, oferă informații despre ritm și conducerea electrică a inimii, în timp ce semnalele neperiodice, precum EEG, permit explorarea activității cerebrale prin benzi de frecvență și potențiale evocate.

Instrumentele moderne combină metodele clasice de procesare cu algoritmi de inteligență artificială, care extind capacitatea de detecție și interpretare. Calitatea semnalului rămâne însă factorul decisiv: dintr-un semnal curat se pot obține concluzii sigure, dintr-un semnal distorsionat — doar aparențe.

Capitolul 7. Prelucrarea imaginilor medicale

7.1. Noțiuni introductive

Imaginea medicală este una dintre cele mai expresive forme de reprezentare a informației biologice. Ea concentrează, într-o singură matrice de valori, structura morfologică și uneori funcțională a țesuturilor examinate. În esență, o imagine este o funcție bidimensională $f(x, y)$ care asociază fiecărui punct o intensitate luminoasă. În cazul imaginilor medicale, această intensitate poate reprezenta un coeficient de absorbție a razelor X (radiografie), amplitudinea unui ecou ultrasonic (ecografie), densitatea protonilor (RMN) sau altă mărime fizică specifică.

Procesul de formare a unei imagini digitale implică două transformări fundamentale: **eșantionarea** și **cuantizarea**.

- *Eșantionarea* constă în împărțirea planului imaginii în puncte discrete, numite **pixeli**, care devin unitățile elementare de reprezentare.
- *Cuantizarea* atribuie fiecărui pixel o valoare numerică, de obicei un întreg între 0 și 255, care indică intensitatea luminoasă sau nivelul de gri.

Astfel, imaginea digitală este o matrice de dimensiuni $M \times N$, unde fiecare element $f(i, j)$ stochează o valoare a luminozității. Numărul de biți folosiți pentru reprezentarea fiecărui pixel definește **adâncimea de culoare**. O imagine pe 8 biți are 256 de niveluri posibile (de la negru la alb), în timp ce o imagine pe 16 biți permite o rezoluție de 65.536 de niveluri, utilă în imagistica medicală, unde diferențele subtile de intensitate pot corespunde diferențelor de densitate tisulară.




Fig. 7.1. Fragment mărit dintr-o radiografie toracică - vizualizarea pixelilor și procesul de digitizare (eșantionare/sampling și cuantizare/quantization)

Un alt atribut al imaginii este **rezoluția spațială** descrie nivelul de detaliu vizual care poate fi diferențiat într-o imagine digitală și depinde direct de dimensiunea imaginii măsurată în pixeli: o rezoluție mai mare semnifică o densitate mai mare de pixeli pe unitatea de suprafață și, implicit, posibilitatea de a surprinde detalii anatomice mai fine, dar și un volum de date mai mare. De exemplu, o radiografie toracică de 2000×2500 pixeli cu 12 biți per pixel ocupă aproximativ 6 MB, iar o scanare CT completă poate depăși 200 MB.




Fig. 7.2. Comparație - rezoluție spațială: scăzută (stg.), medie (centru) și înaltă (dr.)

Rezoluția spațială se exprimă utilizând diverse unități adaptate mediului de afișare sau tipăririi (precum DPI, LPI, PPI), fiecare reflectând densitatea pixelilor, punctelor sau liniilor pe suprafața respectivă, și influențând direct claritatea și gradul de detaliu al imaginii rezultate.

- **DPI (dots per inch)** – utilizat adesea pentru monitoare, desemnează câte puncte fizice sunt redade pe o lungime de un inch pe ecran.
- **LPI (lines per inch)** – folosit în special pentru imprimante laser, exprimă densitatea liniilor tipărite pe inch.
- **PPI (pixels per inch)** – măsoară densitatea pixelilor pe diferite dispozitive (monitoare, tablete, telefoane mobile) și influențează claritatea vizuală pe aceste ecrane.
image.jpg

Imaginile digitale pot fi stocate în mai multe tipuri de formate, fiecare cu propriile caracteristici privind **compresia** și reprezentarea datelor:

- **Lossless compression** (fără pierdere): permite recuperarea exactă a imaginii originale după descompresie; folosită pentru imagini unde detaliile contează (ex.: PNG, TIFF).
- **Lossy compression** (cu pierdere): elimină o parte din informații pentru a reduce dimensiunea fișierului; utilă când este necesară stocarea sau transmiterea rapidă, dar poate introduce artefacte sau pierde detalii fine (ex.: JPG).

Tabel 7.1. Principalele tipuri de imagine

Tip Imagine	Compresie	Utilizare / Scop	Adâncime de culoare
TIFF	Lossless sau fără compresie	Imagini medicale, fotografii cu detalii critice	8, 16, până la 32 biți/canal
BMP	Fără compresie sau lossless	Imagini brute pentru editare sau procesare	1 – 32 biți/pixel
PNG	Lossless	Grafică digitală, transparență, imagini pentru web/prezentări	Până la 48 biți
JPG	Lossy (nivel de compresie ajustabil)	Imagini fotografice (ton continuu)	24 biți
GIF	Lossless	Grafică, ilustrații, imagini cu culori uniforme	8 biți, max. 256 culori

Imaginea digitală nu este o simplă fotografie: ea este o **reprezentare măsurabilă** a unui proces biologic. Spre deosebire de o imagine artistică, interpretarea unei imaginii medicale nu se bazează pe percepția vizuală, ci pe analiză cantitativă și corelare cu datele clinice. De aceea, prelucrarea imaginii nu urmărește „împodobirea” acesteia, ci **extracția obiectivă a informației** relevante pentru diagnostic.

7.2. Tipuri de imagini

Imaginile pot fi clasificate în funcție de modul de reprezentare a informației, dar și de natura fenomenului fizic care stă la baza formării lor. Din punct de vedere informatic, există două mari categorii: **imagini vectoriale** și **imagini raster** (bitmap).

Imaginile **vectoriale** sunt definite prin elemente geometrice – linii, curbe, poligoane, texturi – descrise matematic. Avantajul lor principal este că pot fi redimensionate fără pierdere de calitate, deoarece obiectele sunt regenerate prin ecuații, nu prin pixeli. Ele sunt folosite în diagrame, desene anatomice, reprezentări stilizate ale organelor sau aplicații educaționale interactive. Totuși, imaginile vectoriale nu pot reda detalii reale ale țesuturilor biologice și nu sunt potrivite pentru analiza medicală propriu-zisă.

Imaginile **raster** (bitmap), în schimb, sunt formate dintr-o matrice de pixeli, fiecare cu o valoare numerică ce descrie intensitatea sau culoarea în acel punct. Acestea sunt imaginile „reale” utilizate în medicină: radiografii, tomografii, imagini ecografice sau de rezonanță magnetică. Fiecare pixel corespunde unei mici zone din organul examinat, iar valoarea sa numerică reflectă o proprietate fizică – de exemplu, coeficientul de atenuare a radiației X (în CT) sau intensitatea ecoului ultrasonic (în ecografie).

După sursa informației, imaginile medicale se pot împărți în:

- **Imagini anatomice**, care redau structura morfologică a organelor (radiografie, CT, RMN);
- **Imagini funcționale**, care descriu activitatea metabolică sau circulatorie (SPECT, PET, fMRI);
- **Imagini hibrid**, care combină cele două tipuri (PET/CT, SPECT/CT), oferind simultan informații despre localizare și funcție.

Această trecere de la imagini structurale la imagini funcționale marchează o transformare majoră în practica medicală: scopul nu mai este doar „a vedea” organul, ci **a înțelege dinamica sa biologică**.

De exemplu, o radiografie pulmonară oferă o imagine statică a densităților toracice, dar un examen PET evidențiază zonele de hipermetabolism tumoral chiar înainte de apariția modificărilor anatomice.

Astfel, fiecare tip de imagine aduce o perspectivă complementară, iar interpretarea medicală completă se bazează adesea pe corelarea multiplă a surselor (multimodal imaging).

7.3. Reprezentarea culorilor

Culoarea este o experiență perceptivă, dar în analiza digitală ea trebuie tradusă în mărimi măsurabile. Lumina, în spectrul vizibil (390–780 nm), este o radiație electromagnetică care se propagă sub formă de unde. Culoarea percepută de ochi depinde de compoziția spectrală a luminii reflectate de obiect și de sensibilitatea conurilor retiniene, care răspund la trei regiuni spectrale: roșu, verde și albastru.

Această triadă fiziologică stă la baza **modelului RGB** (Red, Green, Blue), în care orice culoare se obține prin combinarea celor trei componente cu intensități diferite. Un pixel color este descris de trei valori numerice (R, G, B), fiecare variind între 0 și 255. De exemplu, un pixel (255,0,0) corespunde roșului pur, iar (255,255,255) reprezintă albul.

În tipărire și în unele sisteme optice se folosește **modelul CMY(K)** (Cyan, Magenta, Yellow, [Black]), bazat pe amestecul substractiv al culorilor reflectate. Alte modele, precum **HSB** (Hue, Saturation, Brightness) sau **HSL** (Hue, Saturation, Lightness), oferă o reprezentare mai apropiată de percepția umană, separând nuanța de saturație și luminozitate.




Fig. 7.3. Modelul RGB (aditiv) versus CMYK (substractiv)

În imagistica medicală, culoarea are un rol particular. Majoritatea imaginilor clinice sunt **monocrome**, pentru că valorile de interes (densitate, absorbție, intensitate) nu depind de culoare, ci de variația numerică. Totuși, imaginile color sunt folosite în:

- **endoscopie și dermatologie**, unde informația cromatică are relevanță diagnostică (inflamație, perfuzie, pigmentare);

- **imagistica funcțională** (PET, SPECT, fMRI), unde culorile sunt utilizate pentru a codifica intensitatea semnalului metabolic sau activitatea neuronală;
- **vizualizările 3D** sau **hărțile de căldură (heatmaps)**, care asociază culorilor valori cantitative (de ex. temperatură, concentrație, activitate).

Culoarea, în acest context, devine un **instrument de codare vizuală**, nu o proprietate intrinsecă a țesutului. Alegerea paletelor este o decizie tehnică, menită să evidențieze diferențele invizibile în tonuri de gri. O colormap greșită poate conduce la interpretări eronate, de aceea în aplicațiile clinice se preferă scale neutre (grayscale, „hot” sau „viridis”) calibrate pe intervalele fiziologice.

7.4. Achiziția imaginilor biomedicale

Procesul de formare a imaginii medicale este profund legat de natura fizică a semnalului folosit pentru explorarea organismului. Fiecare tehnologie de imagistică transformă un fenomen fizic într-o reprezentare numerică, reflectând proprietăți specifice ale țesuturilor.

Imagistica optică și electronică

Prima formă de imagine medicală a fost cea obținută cu lumină vizibilă – fie prin **fotografie medicală**, fie prin **microscopie**. În ambele cazuri, imaginea rezultă din reflexia sau transmisia luminii. Microscopul optic a revoluționat anatomia patologică, permițând vizualizarea celulelor și a detaliilor tisulare. În epoca digitală, microscopul modern este echipat cu senzori CCD (Charge-Coupled Device) sau CMOS, care transformă fotonii în semnale electrice și apoi în imagini digitale de înaltă rezoluție.




Fig. 7.4. Microscop optic (stg.) Imaginea unei bacterii în microscopia electronică (dr.)

O variantă specială a imagisticii optice este **endoscopia**, care permite vizualizarea directă a organelor cavitare (stomac, bronhii, colon, articulații). Endoscoapele moderne includ surse de lumină LED, camere digitale miniaturizate și posibilitatea de prelevare de biopsii ghidate vizual. Imaginile endoscopice, stocate digital, pot fi analizate ulterior prin tehnici de procesare pentru detectarea automată a leziunilor mucoase.

Imagistica cu raze X

Descoperirea razelor X de către Wilhelm Conrad Röntgen, în 1895, a deschis era imagisticii medicale moderne. Radiografia se bazează pe absorbția diferențiată a radiației X de către țesuturi. Țesuturile dense, precum osul, absorb mai mult și apar albe pe imagine, în timp ce țesuturile moi lasă radiația să treacă, apărând gri.

Din radiografia plană a evoluat **tomografia computerizată (CT)**, care folosește o sursă de raze X rotativă și un detector multiplu. Calculatorul reconstruiește imaginea internă prin analiză matematică (reconstrucție tomografică), obținând secțiuni transversale ale corpului. CT-ul oferă o rezoluție spațială excelentă și este indispensabil în urgențe, dar implică expunere la radiații ionizante.

Imagistica prin rezonanță magnetică (RMN)

RMN-ul este una dintre cele mai sofisticate tehnici imagistice. El nu folosește radiații, ci câmpuri magnetice și unde radio. Protonii din moleculele de apă, supuși unui câmp magnetic puternic, absorb energie și o emit ulterior sub formă de semnal de rezonanță. Intensitatea acestui semnal depinde de densitatea protonilor și de proprietățile locale ale țesutului (timpul de relaxare T_1 și T_2)



Fig. 7.5. Investigație imagistică prin Rezonanță Magnetică

Prin prelucrarea matematică a acestor semnale, se obțin imagini cu contrast excelent între diferite tipuri de țesuturi moi. RMN-ul este deosebit de util în neurologie, ortopedie, imagistica mamară și evaluarea organelor pelviene. Versiunile moderne (fMRI – *functional MRI*) pot măsura activitatea cerebrală prin modificările locale de oxigenare (BOLD signal).

Imagistica ultrasonică

Ecografia folosește unde sonore de înaltă frecvență (1–15 MHz) pentru a explora structurile interne ale corpului. Transductorul ecografic funcționează simultan ca emițător și receptor: trimite unde în țesut, iar ecourile reflectate sunt transformate în semnale electrice și apoi în imagini.

Avantajul major al ecografiei este **neinvazivitatea** și **absența radiațiilor ionizante**. Ea permite explorări dinamice în timp real – de exemplu, monitorizarea bătăilor cardiace fetale sau a fluxului sanguin (prin Doppler).

Totuși, ecografia este dependentă de experiența operatorului și de proprietățile acustice ale mediului (aerul și osul reflectă aproape complet ultrasunetele, limitând accesul la creier sau plămâni).

Imagistica nucleară

Imaginile obținute prin **scintigrafie**, **tomografie cu emisie de pozitroni (PET)** sau **tomografie cu emisie de fotoni unici (SPECT)** reflectă distribuția unei substanțe radioactive injectate în organism. Spre deosebire de radiologie,

unde imaginea depinde de structura anatomică, imagistica nucleară măsoară **activitatea metabolică** a țesuturilor.

PET-ul, de exemplu, folosește un izotop de glucoză marcat (FDG – fluorodeoxiglucoză). Țesuturile cu metabolism crescut (tumori, inflamații) captează mai mult traser, emițând radiații detectate de scanner. Imaginea obținută indică zonele de activitate metabolică, esențiale în oncologie și neurologie.

Combinăția PET/CT sau PET/RMN furnizează informații multimodale: poziția anatomică și funcția biologică, suprapuse într-o singură reprezentare.




Fig. 7.6. Imagini cerebrale obținute prin CT (a), PET (b) și fMRI (c)

Alte metode emergente

Printre tehnologiile recente se numără:

- **Optical Coherence Tomography (OCT)**, care oferă imagini de înaltă rezoluție ale structurilor oculare sau ale vaselor;
- **Termografia infraroșie**, utilizată în evaluarea circulației periferice sau a inflamațiilor;
- **Imaginile hiperspectrale**, care combină informația spectrală și spațială pentru analiza compoziției țesuturilor;
- **Imaginile fotonice și cuantice**, aflate în fază experimentală, care vor redefini limitele de rezoluție și sensibilitate.




Fig. 7.6. Termografia (stg.) Imagine hiperspectrală a brațului (dr.)

7.5. Standardul DICOM și sistemele PACS

În imagistica medicală modernă, fiecare aparat — fie că este vorba despre un tomograf, un RMN, un ecograf sau un sistem endoscopic — generează volume mari de date digitale. Pentru ca aceste date să poată fi stocate, transferate și interpretate uniform între dispozitive diferite, a fost nevoie de un limbaj comun. Acest limbaj este **standardul DICOM** (*Digital Imaging and Communications in Medicine*), creat la sfârșitul anilor '80 de către organizațiile ACR (American College of Radiology) și NEMA (National Electrical Manufacturers Association).

Standardul DICOM definește atât **formatul fișierelor de imagine**, cât și **protocoalele de comunicație** între echipamente medicale. Fiecare fișier DICOM conține două componente:

- imaginea propriu-zisă (matricea de pixeli sau voxeli în cazul imaginilor tridimensionale);
- **metadatele** — informații esențiale despre pacient, modalitate de achiziție, parametri tehnici (doză, câmp magnetic, poziție, orientare) și datele de identificare ale studiului.

DICOM nu este doar un format, ci un **ecosistem de interoperabilitate**. El permite conectarea echipamentelor de la producători diferiți într-o rețea comună de imagistică. Într-un spital modern, tomograful CT, aparatul RMN și ecograful pot transmite imaginile direct către o stație de lucru sau către un server central fără conversii intermediare.

Pe baza acestui standard s-au dezvoltat sistemele **PACS** (*Picture Archiving and Communication Systems*), care reprezintă coloana vertebrală a infrastructurii digitale din radiologie. Un sistem PACS integrează funcţii de:

- **Achiziţie** – preluarea automată a imaginilor de la echipamente;
- **Arhivare** – stocarea pe termen lung, în format DICOM, pe servere dedicate;
- **Comunicare** – distribuirea imaginilor către alte departamente sau instituţii (de exemplu, pentru teleexpertiză);
- **Vizualizare şi interpretare** – interfeţe software pentru medici radiologi, care pot examina imagini 2D şi 3D, ajusta contrastul, măsura distanţe şi volume.

Integrarea PACS cu alte sisteme informatice — **HIS** (Hospital Information System) şi **RIS** (Radiology Information System) — asigură o gestiune completă a fluxului de lucru. Pacientul este identificat o singură dată în HIS, iar imaginile şi rapoartele radiologice sunt automat asociate dosarului său electronic.

În prezent, tendinţa este migrarea către **sisteme PACS distribuite şi cloud-based**, care permit accesul securizat la imagini de oriunde, pe orice dispozitiv autorizat. În paralel, extinderea conceptului DICOM către domenii noi (patologie digitală, oftalmologie, dermatologie) şi integrarea cu standarde precum **HL7-FHIR** marchează tranziţia spre un ecosistem medical complet interoperabil.

Astfel, DICOM nu mai este doar un standard tehnic, ci un **pilon al medicinei digitale**, asigurând nu doar stocarea datelor imagistice, ci şi continuitatea informaţiei clinice pe tot parcursul vieţii pacientului.

7.6. Etapele prelucrării imaginilor

Orice imagine medicală trece, înainte de interpretare, printr-un lanţ de prelucrări menite să transforme informaţia brută în informaţie clinic utilă. Acest lanţ cuprinde mai multe etape, care pot fi privite ca o succesiune logică de conversii: **achiziţie** → **preprocesare** → **segmentare** → **analiză** → **interpretare**.

1. Achiziția imaginii

Achiziția reprezintă prima etapă și presupune captarea semnalului de la senzorii sistemului de imagistică — fie că este un detector de raze X, o bobină de rezonanță magnetică sau un transductor ultrasonic. Calitatea imaginii finale depinde de rezoluția spațială, contrastul, raportul semnal/zgomot și acuratețea calibrației aparatului. În multe cazuri, chiar și în această fază se aplică filtre hardware (de ex. anti-aliasing) pentru a elimina componentele nedorite ale semnalului.

2. Preprocesarea

Preprocesarea are scopul de a îmbunătăți calitatea vizuală a imaginii și de a facilita analiza ulterioară. În această etapă se aplică:

- **corecții de contrast și luminozitate** (prin transformări de intensitate sau egalizarea histogramei);
- **filtrare** pentru reducerea zgomotului (filtru mediu, median, Gaussian);
- **corecții geometrice** (alinieri, redimensionare, rotire) și eliminarea artefactelor de achiziție.

Rezultatul este o imagine „curățată”, cu detalii clar vizibile și distribuție uniformă a intensităților.

3. Segmentarea

Segmentarea reprezintă procesul de separare a regiunilor de interes din imagine — de exemplu, delimitarea unei tumori, a ventriculilor cerebrali sau a unui vas de sânge. Se pot aplica metode bazate pe prag (thresholding), pe regiuni (region growing), pe gradient (Canny, Sobel) sau algoritmi moderni de învățare automată (k-means, CNN).

Succesul segmentării determină calitatea întregii analize ulterioare, deoarece toate măsurătorile și clasificările se bazează pe aceste regiuni extrase.

4. Analiza și descrierea

După segmentare, imaginea este transformată într-un set de **parametri cuantificabili**. Se calculează indicatori precum suprafața, volumul, forma, textura, orientarea sau densitatea structurilor. Acești parametri devin baza

analizelor statistice și a clasificărilor automate (de exemplu, diferențierea între leziuni benigne și maligne).

În aplicațiile moderne, analiza se extinde prin tehnici de *radiomics* — extragerea sistematică a sute de caracteristici numerice din imagini medicale pentru modele predictive integrate cu date clinice.

5. Interpretarea

Ultima etapă, interpretarea, constă în corelarea rezultatelor analitice cu datele clinice ale pacientului. Medicul radiolog sau algoritmul de decizie asistată transformă valorile numerice în semnificație medicală: diagnostice, grad de severitate, recomandări terapeutice.

Astfel, imaginea digitală devine **o sursă de cunoaștere**, nu doar o reprezentare vizuală. De la imaginea brută până la concluzia clinică, procesul parcurge un drum complet de conversie: semnal fizic → imagine numerică → informație → decizie medicală.

7.7. Preprocesarea imaginilor

Preprocesarea reprezintă prima etapă activă din lanțul de analiză a unei imagini medicale. Scopul ei nu este modificarea conținutului informațional, ci **îmbunătățirea calității vizuale și a acurateței datelor numerice**, astfel încât detaliile relevante să devină mai clare pentru medic sau pentru algoritmi de analiză automată.

Imaginea obținută direct de la un sistem de achiziție (radiografie, CT, RMN, ecografie) este adesea afectată de zgomot, variații de iluminare, contrast scăzut sau artefacte produse de mișcarea pacientului. Prin urmare, este necesară aplicarea unor operații preliminare de filtrare, corecție și normalizare.

Corecția contrastului și luminozității

Într-o imagine digitală monocromă, valoarea fiecărui pixel $f(x, y)$ variază între un nivel minim (negru) și unul maxim (alb). Dacă distribuția acestor valori este concentrată într-un interval îngust, imaginea va părea „ștersă”, cu detalii greu de distins.

Pentru a corecta acest efect, se pot aplica transformări de intensitate:

- **Stretching liniar** – extinde intervalul valorilor de gri, redistribuindu-le între 0 și 255;

- **Transformări neliniare** (logaritmice sau de tip putere) – evidențiază detaliile din zonele întunecate sau foarte luminoase.

O metodă foarte eficientă este **egalizarea histogramei**, care ajustează contrastul imaginii astfel încât nivelurile de gri să fie distribuite uniform pe întreaga gamă. Practic, pixelii din zonele mai frecvente sunt „răspândiți”, iar cei din zonele rare sunt amplificați. Rezultatul este o imagine cu detalii mai clare, mai ales în regiunile care anterior păreau uniforme.

 *Exemplu clinic:* egalizarea histogramei este frecvent utilizată în radiografiile pulmonare, pentru a accentua structurile fine ale parenchimului și a evidenția zonele de infiltrație discretă.

Filtrarea și reducerea zgomotului

Zgomotul reprezintă variații ale valorilor pixelilor care nu reflectă proprietăți reale ale țesutului. El poate proveni din limitările senzorului (zgomot termic, electronic), din mișcarea pacientului sau din procesul de transmitere a semnalului.

Pentru eliminarea zgomotului se folosesc **filtre spațiale**, care modifică valoarea fiecărui pixel în funcție de vecinii săi. Cele mai utilizate sunt:

- **Filtrul mediu** (mean filter): înlocuiește valoarea pixelului cu media aritmetică a vecinilor dintr-o fereastră (ex. 3×3). Este simplu, dar poate estompa marginile.
- **Filtrul median:** înlocuiește pixelul cu valoarea mediană a vecinilor; este excelent pentru eliminarea zgomotului de tip „sare și piper” (salt & pepper), fără a distorsiona contururile.
- **Filtrul Gaussian:** aplică o mediere ponderată, în care pixelii mai apropiați de centru au o influență mai mare. Rezultatul este o estompare naturală, menținând formele principale.

Matematic, filtrul Gaussian aplică o convoluție între imagine și o mască $G(x, y)$ definită de funcția:

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (7.1)$$

unde σ controlează gradul de netezire (valoare mare → imagine mai blurată).

 *Exemplu clinic:* filtrul median este utilizat în prelucrarea imaginilor RMN pentru a elimina zgomotele punctiforme cauzate de interferențele electromagnetice, iar filtrul Gaussian este folosit în CT pentru reducerea granulației din imaginile de țesut moale.

Operații aritmetice și logice între imagini

În unele situații, este utilă combinarea a două imagini pentru a evidenția modificările apărute între ele.

Operațiile **aritmetice** includ adunarea, scăderea și înmulțirea pixelilor corespunzători:

- *Scăderea de imagini* ($f_1 - f_2$) este folosită pentru a detecta diferențele dintre două imagini succesive ale aceluiași organ — de exemplu, evoluția unei leziuni tumorale în timp.
- *Adunarea* ($f_1 + f_2$) poate fi utilizată pentru combinarea imaginilor din diferite surse (de exemplu, o imagine CT structurală cu o imagine PET funcțională).

Operațiile **logice** (AND, OR, XOR) se folosesc în segmentarea bazată pe măști: o regiune de interes extrasă (mască binară) este combinată logic cu imaginea originală pentru a izola sau suprapune structuri specifice.

 *Exemplu clinic:* fuziunea imaginilor PET/CT este o aplicație tipică de combinare aritmetică ponderată, care oferă simultan informație despre morfologia și activitatea metabolică a unei tumori.

Corecții geometrice și aliniere

În timpul achiziției, pot apărea distorsiuni geometrice datorate mișcării pacientului, unghiului de înclinare a detectorului sau variațiilor de scală.

Pentru corectare se aplică **transformări geometrice**:

- translații, rotații, redimensionări;
- corecții de perspectivă (warp) și aliniere automată (*image registration*).

Registrarea (alinirea) imaginilor este esențială mai ales în studiile de urmărire (follow-up) sau în imagistica multimodală (de exemplu, suprapunerea CT și PET).

Alinierea se poate face manual sau automat, folosind algoritmi de corelare a intensităților, a trăsăturilor (feature matching) sau a contururilor.

Normalizarea și calibrarea imaginii

Pentru comparabilitatea între examene efectuate pe aparate diferite, este necesară **normalizarea** imaginilor. Aceasta presupune ajustarea intensităților astfel încât același tip de țesut să aibă valori apropiate indiferent de aparat.

De asemenea, imaginile trebuie **calibrate** față de un etalon fizic (de exemplu, o fantomă cu densitate cunoscută) pentru a permite măsurători cantitative corecte.

 *Exemplu clinic:* în tomografia computerizată, valorile de densitate sunt exprimate în **unități Hounsfield (HU)**, calibrate astfel încât apa să aibă 0 HU, iar aerul -1000 HU. Această standardizare permite comparația rezultatelor între pacienți și aparate diferite.

În concluzie, preprocesarea este o etapă de **igienizare digitală** a imaginii. Ea stabilește baza pentru toate operațiile ulterioare — segmentare, măsurare, clasificare — și are un impact direct asupra calității diagnosticului. Un contrast prost reglat, o filtrare excesivă sau o aliniere imprecisă pot altera semnificativ informația vizuală, ducând la erori de interpretare. De aceea, alegerea și parametrarea metodelor de preprocesare trebuie să fie adaptate fiecărui tip de imagine, scopului analizei și contextului clinic.

7.8. Segmentarea imaginilor

Segmentarea este etapa în care imaginea medicală este împărțită în regiuni sau structuri distincte, fiecare corespunzând unui element anatomic sau unei zone de interes clinic. Spre deosebire de preprocesare, care îmbunătățește imaginea în ansamblu, segmentarea **izolează** componentele relevante pentru diagnostic sau măsurare.

Scopul segmentării este **extracția obiectivă a contururilor și a regiunilor** care corespund unor structuri specifice: conturul unei tumori, delimitarea ventriculilor cerebrali, separarea țesutului osos de cel moale sau identificarea vaselor de sânge. Fără segmentare, măsurătorile cantitative volumul unei leziuni, suprafața unui infarct, densitatea unui țesut ar fi imposibile.

Segmentarea nu este un proces universal există metode specializate pentru fiecare tip de imagine și pentru fiecare tip de structură. Alegerea metodei depinde de:

- **contrastul** dintre regiunile de interes și fundal;
- **forma** structurilor (regulate sau neregulate, omogene sau texturate);
- **nivelul de zgomot** din imagine;
- **scopul clinic** (diagnostic rapid versus analiză de cercetare).




Fig. 7.7. Aplicații ale procesului de segmentare

Principalele categorii de metode de segmentare includ: **segmentarea bazată pe prag, pe regiuni, pe margini, pe texturi** și, mai recent, **segmentarea prin învățare automată**.

Segmentarea prin prag (thresholding)

Cea mai simplă metodă de segmentare constă în alegerea unui **nivel de gri critice**, numit prag, care împarte pixelii în două categorii: cei aparținând obiectului de interes și cei aparținând fundalului.

Dacă valoarea unui pixel $f(x, y)$ este mai mare decât pragul T , atunci pixelul este considerat parte din obiect. Altfel, este considerat fundal. Rezultatul este o **imagine binară**, în care obiectele apar albe, iar fundalul negru (sau invers). Metoda este eficientă atunci când există o separare clară între intensitățile obiectului și cele ale fundalului — de exemplu, delimitarea oaselor (densitate mare) de țesuturile moi (densitate mică) într-o radiografie sau separarea vaselor de sânge (contrast ridicat) de parenchimul cerebral într-o angiografie.

Pragul poate fi:

- **fix**, stabilit manual de utilizator în funcție de cunoștințele despre imagine;
- **adaptiv**, calculat automat pe baza histogramei imaginii (de ex. metoda Otsu);
- **local**, variabil în diferite zone ale imaginii, pentru a compensa variații de iluminare sau contrast.

Limitele metodei sunt evidente în imaginile cu contrast scăzut sau cu distribuții de intensitate suprapuse. De exemplu, într-o ecografie abdominală, ficatul și splina pot avea intensități similare, ceea ce face ca pragul simplu să fie insuficient.

Exemplu clinic: segmentarea oaselor dintr-o tomografie computerizată (CT) se realizează cu succes prin thresholding, deoarece țesutul osos are valori Hounsfield (HU) foarte diferite de cele ale țesuturilor moi sau ale aerului.

Segmentarea bazată pe regiuni

Această categorie de metode pornește de la ipoteza că pixelii dintr-o regiune au **proprietăți comune** (intensitate, textură, culoare). Principala tehnică este **creșterea regiunilor** (*region growing*), care începe de la un pixel inițial (*seed*) și extinde treptat regiunea, adăugând pixelii vecini care îndeplinesc un criteriu de similaritate.

Procesul se oprește atunci când nu mai există pixeli vecini care să respecte condiția. Această metodă este utilă în cazurile în care structura de interes este compactă și relativ omogenă — de exemplu, delimitarea unei tumori cerebrale pe o imagine RMN.

Metoda este sensibilă la **alegerea seed-ului inițial** și la **criteriul de similaritate**. Un prag prea restrictiv va duce la subsegmentare (regiuni incomplete), iar un prag prea lax va include pixeli din afara obiectului.

O variantă mai evoluată este **divizarea și combinarea regiunilor** (*split-and-merge*), care împarte imaginea în pătrate mici, apoi le îmbină dacă satisfac criterii comune.

 *Exemplu clinic:* delimitarea ventriculilor cerebrali dintr-o imagine RMN prin region growing, pornind de la un pixel din interiorul ventriculului.

Segmentarea bazată pe margini (edge detection)

Marginile sunt zonele în care intensitatea imaginii variază brusc. Acestea corespund, de obicei, **conturilor anatomice** — limita dintre organ și țesutul adiacent, suprafața unei tumori, conturul unui os.

Deteția marginilor se bazează pe operatori matematici care măsoară **gradientul imaginii**, adică rata de schimbare a intensității pe direcțiile orizontală și verticală. Principalii operatori sunt:

- **Sobel** — combină derivata pe x și pe y , evidențiind marginile cu o sensibilitate medie la zgomot;
- **Prewitt** — similar cu Sobel, dar cu o mască de convoluție ușor diferită;
- **Canny** — unul dintre cei mai performanți operatori; aplică mai multe etape: filtrare Gaussiană, calcul gradient, suprimarea non-maximelor și praguri duble pentru a obține margini fine și continue;
- **Laplacianul** — un operator de ordinul doi, sensibil la zgomot, dar util pentru detectarea rapidă a conturilor.

Avantajul metodelor bazate pe margini este că **nu necesită cunoștințe prealabile** despre forma obiectului. Limitele apar atunci când marginile sunt întrerupte sau atunci când zgomotul produce contururi false.

Exemplu clinic: detectarea conturului inimii pe o radiografie toracică prin operatorul Canny, folosit ulterior pentru măsurarea dimensiunilor cardiace.

Segmentarea prin clustering și învățare automată

Metodele moderne de segmentare utilizează algoritmi care **grupează automat pixelii** pe baza caracteristicilor lor numerice. Printre acestea:

- **k-means clustering** — împarte pixelii în k clase, fiecare clasă corespunzând unei regiuni cu intensitate medie similară;
- **fuzzy c-means** — o variantă în care fiecare pixel poate aparține mai multor clase cu grade diferite de apartenență;
- **rețele neuronale convoluționale (CNN)** — arhitecturi precum **U-Net**, **Mask R-CNN** sau **DeepLab** au revoluționat segmentarea imaginilor medicale, obținând performanțe superioare metodelor clasice, mai ales în cazul structurilor complexe (tumori eterogene, vase tortuoase, leziuni difuze).

Aceste metode bazate pe AI **învață** din seturi mari de imagini manual anotate de experți și pot generaliza la cazuri noi, chiar dacă acestea nu au fost întâlnite în timpul antrenării.

 *Exemplu clinic:* segmentarea automată a tumorilor pulmonare dintr-un CT toracic prin rețele U-Net, cu precizie comparabilă cu cea a unui radiolog experimentat.

Provocări

Segmentarea imaginilor medicale rămâne o provocare din cauza:

- **variabilității anatomice** între pacienți;
- **artefactelor** de achiziție (mișcare, zgomot, distorsiuni);
- **suprapunerii structurilor** (de ex. în radiografiile plane);
- **lipsei de contrast** între țesuturi similare.

Evoluția actuală merge spre **metode hibride**, care combină segmentarea clasică cu algoritmi AI, asigurând atât precizie, cât și interpretabilitate clinică. Integrarea segmentării automate în fluxul de lucru medical reduce timpul necesar pentru diagnosticare și permite măsurători cantitative precise, esențiale pentru monitorizarea evoluției bolilor și pentru evaluarea răspunsului la tratament.

7.9. Descrierea și recunoașterea imaginilor

După ce o imagine a fost segmentată, ea devine o **matrice binară sau o regiune delimitată**. Din această regiune trebuie extrase **parametri numerici** care să descrie forma, textura, densitatea sau alte caracteristici relevante clinic. Această etapă se numește **descriere** sau **extragere de caracteristici** (*feature extraction*).

Parametrii extrași devin apoi **descriptori**, adică valori numerice care permit compararea, clasificarea sau recunoașterea automată a structurilor. De exemplu, o tumoră poate fi caracterizată prin volum, formă (sferică, neregulată), densitate medie, omogenitate sau heterogenitate texturală.

Tipuri de descriptori

Descriptori de **formă** includ:

- **Suprafața și volumul** — calculate prin numărarea pixelilor sau voxelilor din regiune;
- **Perimetrul și compacitatea** — raportul dintre suprafață și perimetru indică dacă o structură este rotundă (compactă) sau neregulată (invazivă);
- **Centrul de masă și orientarea** — utilizate pentru aliniere și urmărire în timp;
- **Diametrul și alungirea** — utile pentru distincția între structuri normale și patologice.

Descriptori de **textură** descriu aranjamentul spațial al intensităților:

- **Histograma** — distribuția nivelurilor de gri;
- **Matrice de co-ocurență** (GLCM) — evaluează relațiile dintre pixelii vecini și permite calculul indicilor de omogenitate, contrast, entropie;
- **Transformata Fourier** sau **Wavelet** — analizează structura frecvențială a texturii.

Descriptori de **intensitate**:

- **Media, mediana, abaterea standard** a intensităților din regiune;
- **Valorile extreme** (minim, maxim) — relevante în CT pentru distincția între țesuturi.

 *Exemplu clinic:* clasificarea unei leziuni pulmonare ca benignă sau malignă pe baza compacității (leziunile maligne tind să fie neregulate) și a heterogenității texturale (tumorile au adesea zone necrotice sau calcificate).

Recunoașterea și clasificarea

Odată extrași descriptorii, următorul pas este **recunoașterea** — adică asocierea regiunii segmentate cu o **clasă** (diagnostic). Procesul se bazează pe algoritmi care compară descriptorii observați cu modele prestabilite sau cu baze de date de referință.

Metodele clasice includ:

- **Clasificatori statistici** — *k-nearest neighbors* (k-NN), *Support Vector Machines* (SVM), arbori de decizie;
- **Rețele neuronale artificiale** — inclusiv rețele profunde (CNN), care pot învăța automat atât extragerea de caracteristici, cât și clasificarea.

Clasificarea poate fi:

- **supervizată** — algoritmul este antrenat pe imagini etichetate de experți;
- **nesupervizată** — algoritmul grupează singur imaginile pe baza similarității, fără etichete inițiale.

În practică, se preferă metodele supervizate, deoarece diagnosticul medical trebuie validat prin corelație cu adevărul clinic (histopatologie, evoluție clinică).

 *Exemplu clinic:* sistem automat de detecție a retinopatiei diabetice din imagini de funduscopie, antrenat pe zeci de mii de imagini etichetate de oftalmologi.

Radiomics — extragerea sistematică de informație cantitativă

Un domeniu emergent este **radiomics**, care constă în extragerea automată a sute sau chiar mii de caracteristici numerice din imagini medicale — forme geometrice, texturi, intensități, relații spațiale — și utilizarea acestora pentru:

- predicția răspunsului la tratament;
- stratificarea riscului oncologic;
- identificarea biomarkerilor imagistici.

Prin corelarea acestor date cu parametri clinici, genetici și de laborator, se obțin **modele predictive integrate**, care ghidează deciziile terapeutice personalizate.

Radiomics transformă imaginea dintr-o simplă reprezentare vizuală într-o **sursă cantitativă de cunoaștere medicală**.




Fig. 7.8. Schema modelului radiomic standard. (1) Achiziție de imagini RMN multiparametrice (mpMRI). (2) Segmentare: etichetare tumorală - contur verde/alb. (3) Extragerea caracteristicilor imagistice folosind formă, textură și/sau caracteristici profunde derivate din straturile rețelei neuronale convoluționale. (4) Caracteristici clinice, radiomice, date moleculare pentru analize statistice, teste de semnificație bazate pe modele de clasificare. Sursa: Wikimedia Commons Autor: Chaddad, A et. all. Licența CC BY-SA 4.0

7.10. Aplicații avansate — Realitate virtuală, augmentată și mixtă

Evoluția tehnologiilor de imagistică medicală nu s-a oprit la achiziție, preprocesare și segmentare. În ultimii ani, integrarea imaginilor medicale cu **realitatea virtuală (VR)**, **realitatea augmentată (AR)** și **realitatea mixtă (MR)** a deschis noi orizonturi pentru educație, planificare chirurgicală și asistență în timpul intervențiilor.

Realitatea virtuală (VR)

Realitatea virtuală creează un **mediu complet imersiv**, generat digital, în care utilizatorul poate interacționa cu structuri tridimensionale. În medicină, VR este utilizată pentru:

- **Educația medicală** — studenții pot explora modele 3D ale inimii, creierului sau altor organe, vizualizând structurile din orice unghi, secționându-le virtual sau simulând intervenții;
- **Planificarea chirurgicală** — pe baza datelor imagistice (CT, RMN), se reconstruiește un model 3D al inimii pacientului, care poate fi examinat în cel mai mic detaliu, permițând chirurgului să evalueze anatomia complexă și să simuleze intervenția înainte de operație;
- **Reabilitare** — pacienții cu deficite neurologice pot folosi medii VR pentru terapie prin expunere sau exerciții motorii ghidate.

 *Exemplu clinic:* un chirurg cardiac poate importa un model 3D al inimii unui pacient pediatric cu malformație congenitală complexă și poate simula intervenția într-un mediu VR, anticipând dificultățile și optimizând strategia operatorie.

Realitatea augmentată (AR)

Realitatea augmentată **suprapune imagini digitale** peste mediul real, vizibile prin ecrane, tablete sau ochelari speciali. Spre deosebire de VR, utilizatorul rămâne conectat la mediul fizic, dar primește informații suplimentare vizuale. În medicină, AR este folosită pentru:

- **Ghidare intraoperatorie** — proiecția pe corpul pacientului a pozițiilor vaselor de sânge, nervilor sau tumorilor, vizibile pe baza unei scanări CT/RMN preoperatorii;
- **Instruire medicală** — studenții pot vedea, prin ochelari AR, structurile anatomice suprapuse pe un manechin sau chiar pe un pacient virtual;
- **Telemedicină asistată** — un specialist la distanță poate „desena” în spațiul de lucru al medicului aflat la fața locului, ghidându-l în timp real.

 *Exemplu clinic:* în timpul unei intervenții neurochirurgicale, chirurgul poartă ochelari AR care afișează conturul tumorii cerebrale și traiectul vaselor adiacente, facilitând rezecția precisă fără lezarea structurilor vitale.

Realitatea mixtă (MR)

Realitatea mixtă combină elemente din VR și AR, permițând interacțiunea directă cu obiecte digitale plasate în mediul real. Tehnologii precum **Microsoft HoloLens** au fost deja testate în educație și chirurgie. Un exemplu reprezentativ este **HoloAnatomy®**, o aplicație care permite studenților să exploreze structuri anatomice 3D holografice, să le rotească, să le secționeze și să le manipuleze ca și cum ar fi obiecte fizice.

În chirurgie, MR permite **suprapunerea modelului 3D al organului pacientului** direct pe masa de operație, oferind o perspectivă spațială precisă și integrată.

 *Exemplu clinic:* într-o intervenție de implantare a unei proteze de șold, modelul 3D al bazinului pacientului este proiectat holografic, permițând chirurgului să vizualizeze unghiul optim de plasare a implantului, direct în raport cu structura osoasă reală.

Impactul asupra educației și practicii medicale

Aceste tehnologii aduc beneficii multiple:

- **Învățare accelerată și mai profundă** — studenții pot interacționa cu structuri anatomice într-un mod imposibil cu atlasele clasice;
- **Reducerea riscurilor chirurgicale** — prin simulare și planificare detaliată înainte de operație;
- **Creșterea preciziei** — prin ghidare vizuală în timp real;
- **Colaborare la distanță** — experții pot asista intervenții din alte locații, vizualizând aceeași scenă augmentată.

Totuși, implementarea acestor tehnologii presupune:

- **costuri mari** de echipament și software;
- **necesitatea antrenării** personalului medical;
- **validarea clinică** a aplicațiilor pentru siguranța pacientului;
- **integrarea** cu sistemele PACS și cu fluxul de lucru existent.

Pe viitor, se anticipează că VR, AR și MR vor deveni instrumente standard în sălile de operație și în centrele universitare, transformând modul în care se învață, se planifică și se execută actul medical.

Concluzii

Prelucrarea imaginilor medicale este un domeniu vast și dinamic, aflat la intersecția dintre fizică, matematică, informatică și medicină. De la achiziția semnalului fizic — fie el radiație X, ecou ultrasonic sau semnal de rezonanță magnetică — până la interpretarea clinică, fiecare etapă transformă informația brută într-o cunoaștere utilă pentru diagnostic, tratament și cercetare.

Procesul parcurge mai multe trepte fundamentale:

- **Achiziția**, care transformă fenomenul biologic într-o matrice numerică;
- **Preprocesarea**, care îmbunătățește calitatea vizuală și pregătește imaginea pentru analiză;
- **Segmentarea**, care izolează structurile de interes;
- **Descrierea**, care extrage parametri cantificabili;
- **Recunoașterea și clasificarea**, care transformă acești parametri în informație diagnostică.

Fiecare dintre aceste etape poate fi realizată prin metode clasice — bazate pe reguli matematice, filtre, operatori de gradient — sau prin **metode moderne de învățare automată**, care permit automatizarea și scalarea analizei la volume mari de date.

Standardele precum **DICOM** și infrastructurile **PACS** asigură interoperabilitatea echipamentelor și integrarea imaginilor în dosarele electronice de sănătate. În același timp, noile tehnologii — **realitate virtuală, augmentată și mixtă** — extind utilizarea imaginilor medicale dincolo de diagnostic, integrându-le în educație, planificare chirurgicală și asistență intraoperatorie.

Pentru viitorul medic, înțelegerea acestor principii nu înseamnă doar familiarizarea cu tehnologia, ci și **dezvoltarea capacității de a evalua critic** calitatea imaginilor, de a recunoaște limitele metodelor și de a colabora eficient cu specialiștii în imagistică și cu algoritmi de analiză automată.

Imaginea medicală nu mai este o simplă fotografie a corpului — **ea devine o sursă de date cantitative, o hartă biologică și un instrument de decizie**. Și, în era inteligenței artificiale, această imagine este din ce în ce mai mult analizată, interpretată și utilizată în parteneriat cu algoritmi inteligenți, care pot detecta anomalii invizibile ochiului uman și pot anticipa evoluții clinice pe baza tiparelor învățate din milioane de cazuri.

Astfel, informatica medicală aplicată imaginilor devine nu doar un suport tehnic, ci **o componentă esențială a medicinei moderne**, care transformă modul în care vedem, înțelegem și tratăm boala.

De reținut

- Segmentarea izolează structuri de interes din imagini pentru măsurători cantitative și diagnostic.
- Descrierea și clasificarea permit extragerea de parametri numerici și recunoașterea automată a structurilor patologice.
- Realitatea virtuală, augmentată și mixtă extind utilizarea imaginilor în educație, planificare și asistență chirurgicală.
- Standardul DICOM și sistemele PACS asigură interoperabilitatea și integrarea în fluxul de lucru medical.

Partea III

De la cunoaştere la decizie

Capitolul 8 – Sisteme informatice medicale

8.1. Informația medicală pe nivele de asistență

Informația medicală este una dintre cele mai valoroase resurse ale unui sistem de sănătate. Ea reflectă starea de sănătate a populației, calitatea serviciilor, eficiența utilizării resurselor și nivelul de performanță al instituțiilor. Într-un sens larg, informația medicală include toate datele generate, prelucrate și utilizate în procesul de prevenție, diagnostic, tratament și monitorizare a pacienților, dar și în activitățile administrative, de cercetare sau planificare sanitară.

Pentru a înțelege fluxul informațional din sănătate, trebuie să privim sistemul medical ca pe o structură stratificată, în care datele se colectează, se sintetizează și se consolidează treptat, de la nivelul individual al pacientului până la nivelul național și internațional. Acest proces de agregare verticală reflectă organizarea instituțională a asistenței medicale.

Nivelul primar de asistență

La baza piramidei se află **asistența medicală primară**, reprezentată în principal de medicii de familie și cabinetele individuale. Aici se colectează datele fundamentale despre pacient: date demografice, istoricul bolilor, vaccinările, alergiile, medicația curentă și rezultatele analizelor de rutină. Informația la acest nivel are o valoare longitudinală — adică urmărește evoluția pacientului de-a lungul vieții. Rolul său este de a asigura continuitatea îngrijirilor și de a furniza un tablou complet, integrat, care să însoțească pacientul pe tot parcursul sistemului.

Digitalizarea acestui nivel se realizează prin **sistemele informatice de cabinet** interconectate cu **dosarul electronic de sănătate (EHR)**. În mod ideal, medicul de familie poate accesa rezultatele analizelor de laborator, istoricul rețetelor și rapoartele de externare, fără a solicita duplicarea investigațiilor.

Nivelul secundar – asistența de specialitate și spitalicească

La nivelul următor se află **asistența medicală de specialitate**, care include ambulatoriile, policlinicile și spitalele. Aici informația medicală devine mult mai complexă: se adaugă date imagistice, rapoarte de laborator, fișe de internare, protocoale chirurgicale și date farmacologice. Sistemele informatice utilizate la acest nivel sunt, de obicei, **HIS** (Hospital

Information Systems), **LIS** (Laboratory Information Systems), **RIS** (Radiology Information Systems) și **CIS** (Clinical Information Systems). Aceste aplicații gestionează atât activitățile clinice, cât și cele administrative: programări, gestiunea paturilor, facturare, raportări către casele de asigurări. Un aspect critic este integrarea acestor sisteme într-un **sistem informatic spitalicesc integrat**, în care toate departamentele comunică prin protocoale comune. În lipsa acestei integrări, datele rămân fragmentate în silozuri, iar procesul de luare a deciziilor devine lent și inefficient. În spitalele moderne, sistemele clinice furnizează automat date către dosarul pacientului, actualizând în timp real evoluția tratamentului.

Nivelul terțiar și central – administrația și politicile publice

Datele colectate de la nivelurile primar și secundar sunt consolidate la nivel regional și național pentru scopuri de **management sanitar, planificare și politici publice**. Acest nivel terțiar include direcțiile de sănătate publică, casele de asigurări, ministerul sănătății și organisme internaționale (OMS, Eurostat, ECDC).

La acest nivel, informația medicală nu mai este privită individual, ci statistic, agregată și anonimă. Ea servește la identificarea tendințelor epidemiologice, evaluarea performanței spitalelor, monitorizarea costurilor și fundamentarea deciziilor strategice (de exemplu, planificarea resurselor umane, programelor de screening sau bugetelor de sănătate).

Sistemele informatice care susțin acest nivel sunt cele de tip **Business Intelligence (BI)** și **Health Data Warehouse**, care integrează volume mari de date din surse multiple, oferind analize și rapoarte sintetice.

Exemplu practic: în România, datele transmise de spitale către CNAS și Ministerul Sănătății prin SIUI (Sistemul Informatic Unic Integrat) sunt ulterior utilizate pentru raportări statistice către OMS și pentru planificarea programelor naționale.

Fluxul informațional și integrarea verticală

Fluxul informațional medical este bidirecțional. Pe de o parte, datele urcă de la nivelul individual la cel instituțional, fiind agregate și analizate. Pe de altă parte, informațiile rezultate (ghiduri, protocoale, alerte epidemiologice) coboară spre practicieni, închizând ciclul de feedback.

Un sistem informatic performant trebuie să asigure această **continuitate a informației** între nivelurile de asistență. Astfel, medicul de familie,

specialistul, spitalul și autoritățile pot lucra pe baza aceluiași set de date, eliminând erorile de transcriere și pierderile de informație.(Fig. 8.1).

Într-o viziune modernă, informația medicală nu mai aparține unei singure instituții, ci pacientului însuși, care devine centrul rețelei informaționale. Dosarul său electronic (EHR) este accesibil – cu acordul său – de către toți profesioniștii implicați, indiferent de nivelul de asistență sau de locație




Fig. 8.1. Dosarul Electronic de Sănătate

În esență, informația medicală traversează un circuit complet, de la pacient la sistemul național și înapoi, într-un proces continuu de **producere, validare și reutilizare a datelor**. Fiecare nivel de asistență contribuie la acest circuit, iar eficiența sistemului depinde de coerența legăturilor dintre ele. Digitalizarea sănătății nu înseamnă doar informatizarea spitalelor, ci crearea unei **infrastructuri informaționale integrate**, în care datele circulă liber, sigur și standardizat, punând pacientul în centrul ecosistemului medical.

8.2. Sisteme informaționale și sisteme informatice

Orice organizație care desfășoară activități complexe are nevoie de mecanisme prin care să colecteze, să proceseze și să folosească informația în mod eficient.

În domeniul medical, această nevoie este deosebit de evidentă: volumul de date generat zilnic este imens, provenind din surse diverse – fișe de consultație, analize de laborator, investigații imagistice, prescripții, programe de screening, statistici epidemiologice. Gestionarea acestor fluxuri de informație nu poate fi realizată fără un sistem organizat.

De aceea, se face o distincție importantă între **sistemul informațional** și **sistemul informatic**, două concepte adesea confundate, dar fundamental diferite.

Sistemul informațional medical

Sistemul informațional este ansamblul total al fluxurilor de informație dintr-o organizație: datele care se produc, se prelucrează și se transmit între oameni, servicii și instituții. În sănătate, el cuprinde toate procesele prin care se generează informație relevantă pentru îngrijirea pacientului, pentru managementul resurselor și pentru luarea deciziilor la nivel strategic.

Într-un spital, de exemplu, sistemul informațional include nu doar bazele de date și echipamentele de calcul, ci și documentele pe hârtie, telefoanele, formularele, traseele de aprobare, comunicarea verbală și toate celelalte canale prin care circulă informația. Pe scurt, sistemul informațional este infrastructura conceptuală care descrie „cine, ce informație produce și cui o transmite”.

El poate fi reprezentat schematic ca o rețea de fluxuri: **intrări** (date clinice, administrative, financiare), **proces** (analiză, validare, stocare, raportare) și **ieșiri** (decizii medicale, rapoarte, recomandări). Înainte de apariția calculatoarelor, aceste procese erau exclusiv manuale; astăzi, ele sunt în mare parte digitalizate, dar principiile de funcționare rămân aceleași.

Fluxurile informaționale pot fi:

- **Fluxuri Clinice:** Transportă informații legate direct de îngrijirea pacientului. Exemplu: un medic specialist introduce un diagnostic în sistem, care ajunge automat la medicul de familie și apare în raportul de externare.
- **Fluxuri Administrative/Manageriale:** Cuprind date necesare pentru funcționarea instituției. Exemplu: programarea unui pacient generează un flux informațional către departamentul de facturare pentru a emite o factură către casa de asigurări.

Sistemul informatic medical

Sistemul informatic, în schimb, reprezintă componenta tehnologică a sistemului informațional. Este instrumentul care automatizează prelucrarea datelor și facilitează transmiterea și accesul la informație. El cuprinde **hardware-ul, software-ul, baza de date, rețelele de comunicație** și interfața cu **utilizatorii** care interacționează cu sistemul.

Într-un spital, sistemul informatic gestionează fișele pacienților, rezultatele analizelor, programările, prescrierile, aprovizionarea cu medicamente și chiar fluxurile financiare. În loc ca un registru să fie completat manual, datele sunt introduse într-o interfață electronică și pot fi accesate simultan din mai multe puncte.

Astfel, sistemul informatic transformă informația dintr-o formă statică într-una dinamică, interconectată. Medicul poate accesa instantaneu istoricul pacientului, farmacistul vede tratamentul prescris, iar laboratorul primește automat solicitările de analiză.

Prin urmare, **sistemul informațional descrie fluxurile**, iar **sistemul informatic le susține tehnologic**.

Componentele unui sistem informatic medical

Un sistem informatic complet include:

1. **Componenta umană** – personalul medical și administrativ care introduce, validează și utilizează informațiile;
2. **Datele** – elementele de bază (rezultate, observații, parametri, costuri);
3. **Procese** – regulile și procedurile care guvernează transformarea datelor în informație;
4. **Infrastructura hardware și software** – servere, rețele, aplicații clinice;
5. **Mecanismele de securitate și guvernare a datelor** – pentru asigurarea confidențialității și integrității.

Aceste componente trebuie să funcționeze în echilibru. O tehnologie performantă nu poate compensa lipsa unei structuri informaționale coerente, iar un sistem informațional bine gândit devine inefficient fără suportul tehnologic adecvat.

În funcție de domeniul pe care îl deservește, sistemele informatice medicale se împart în:

1. **Sisteme Clinice:** Sunt axate pe procesul de îngrijire a pacientului.
 - **CIS (Clinical Information System):** Sistemul central care gestionează datele clinice ale pacienților internati (semne vitale, observații, plan terapeutic).
 - **LIS (Laboratory Information System):** Gestionează cererile de analize, urmărește probele și stochează rezultatele.
 - **RIS (Radiology Information System):** Folosit pentru programarea pacienților, gestionarea dosarelor radiologice și raportarea investigațiilor imagistice.
 - **PACS (Picture Archiving and Communication System):** Arhivează și distribuie imagini medicale (RMN, CT, radiografii), integrându-se cu RIS.
2. **Sisteme Administrative:** Sprijină operațiunile de business ale unității sanitare.
 - **PAS (Patient Administration System):** Modulul care gestionează înregistrarea, admiterea, transferul și externarea pacienților.
 - **Sistemul de Facturare:** Elaborează facturi pentru serviciile prestate, pe baza diagnosticului și procedurilor efectuate (de exemplu, conform grupelor DRG).
 - **Sistemul de Management al Stocurilor:** Urmărește aprovizionarea cu medicamente și materiale consumabile.
3. **Sisteme Integrate (Enterprise Systems):** Sunt platforme cuprinzătoare care unifică funcțiile clinice și administrative, distrugând „silozurile” de date.

HIS (Hospital Information System) reprezintă „creierul” digital al spitalului. Un HIS integrat asigură că toate sistemele menționate mai sus comunică între ele. Când un medic prescrie un tratament în CIS, acesta este reflectat automat în sistemul de farmacie (management stoc) și, ulterior, în cel de facturare. În trecut, fiecare departament (laborator, radiologie, farmacie) își putea deține propriul sistem informatic, care nu comunica cu celelalte — acestea erau **silozuri informaționale**. Aceasta ducea la fragmentarea informației, repetarea investigațiilor și erori de coordonare.

Soluția este implementarea de **sisteme informatice integrate**, care asigură:

- **Un singur punct de introducere a datelor:** O informație introdusă o dată este utilizată de toate.
- **Vedere globală asupra pacientului:** Profesioniștii au acces la o imagine completă și actualizată.
- **Eficiență operațională:** Reducerea pașilor manuali și a documentației duplicate.



Exemplu practic de flux integrat: Un pacient este internat de urgență. Asistentul îl înregistrează în **PAS**. Medicul ordonă analize în **CIS**, care sunt transmise electronic în **LIS**. Rezultatele, odată validate, apar automat în fișa pacientului din **CIS**. Pe baza acestora, medicul prescrie un medicament, iar comanda ajunge electronic în **sistemul farmaciei**. La externare, **sistemul de facturare** primește automat toate procedurile și medicamentele pentru a genera factura către asigurator.

În unitățile moderne, toate aceste subsisteme comunică cu **dosarul electronic de Sănătate (Electronic Healthcare Record - EHR)**, permițând o imagine completă și unitară asupra actului medical.

Evoluția de la sisteme izolate la sisteme integrate

Inițial, fiecare departament al unui spital își dezvoltă propriul sistem informatic, adaptat nevoilor locale. Această abordare fragmentată a dus la existența unor „insule informatice” între care comunicarea era dificilă.

În prezent, tendința este clară: **integrarea sistemelor**. Prin protocoale de interoperabilitate (HL7, FHIR, DICOM), aplicațiile pot comunica între ele, iar datele pacientului circulă liber între departamente și între instituții. Astfel, se reduce timpul de reacție, se evită erorile de duplicare și se îmbunătățește siguranța pacientului.

În sistemele moderne, componenta informatică devine parte a infrastructurii critice a spitalului. O întrerupere de câteva ore a rețelei poate bloca internările, prescrierile și raportările. Prin urmare, sistemele informatice medicale nu mai sunt doar instrumente administrative, ci **coloana vertebrală a funcționării instituției medicale**.

În concluzie, sistemul informațional definește arhitectura logică a fluxurilor de informație, iar sistemul informatic o realizează concret, prin mijloace

tehnice. Împreună, ele asigură funcționarea coerentă a instituțiilor medicale, transformând datele dispersate în informație organizată, accesibilă și utilă.

Trecerea de la registre pe hârtie la sisteme informatice integrate marchează una dintre cele mai profunde transformări ale medicinei moderne: de la practici izolate, la un ecosistem digital conectat, centrat pe pacient și pe datele sale.

8.3. Dosarul electronic de sănătate (EHR)

În centrul oricărui sistem informatic medical modern se află **dosarul electronic de sănătate**, prescurtat **EHR** (*Electronic Healthcare Record*). Acesta reprezintă nucleul integrator al tuturor informațiilor despre pacient, indiferent de instituția în care au fost generate, de furnizorul de servicii sau de momentul în care au fost înregistrate.

Conceptul de EHR reflectă o schimbare fundamentală de perspectivă: informația medicală nu mai aparține instituției, ci **pacientului**. Medicul, laboratorul, spitalul sau casa de asigurări devin doar furnizori și utilizatori autorizați ai datelor, nu proprietarii lor.

Evoluția de la EMR la EHR

Primele aplicații informatice medicale au fost simple fișe electronice utilizate în spitale – **EMR** (*Electronic Medical Record*) – care stocau informații despre internări, tratamente și rezultate de laborator. Ele reflectau activitatea unei singure unități medicale și nu puteau fi partajate.

Ulterior au apărut **EPR** (*Electronic Patient Record*), orientate pe pacient, care adunau datele din mai multe servicii ale aceluiași spital. Totuși, nici acestea nu ofereau interoperabilitate completă.

EHR extinde aceste concepte la nivel regional sau național: este o colecție de date informatizate privind starea de sănătate a unui individ, accesibilă, în mod securizat, utilizatorilor autorizați, oriunde și oricând. Definiția consacrată de **ISO/TR 20514:2005** precizează și faptul că EHR are implementat un model de organizare logică a informației, universal recunoscut și independent de sistem. În plus, are ca scop asigurarea continuă, eficientă și de calitate a serviciilor de sănătate integrate și conține informații retrospective, concurente și prospective.

Rolul și beneficiile EHR

EHR servește mai multe scopuri esențiale:

- **continuitatea îngrijirilor** – medicul de familie, specialistul și spitalul pot accesa același istoric medical, evitând duplicarea analizelor și erorile de medicație;
- **suportul deciziei clinice** – sistemele pot semnaliza interacțiuni medicamentoase, contraindicații sau alerte preventive;
- **siguranța pacientului** – datele esențiale (alergii, grupa sanguină, boli cronice) sunt disponibile în situații de urgență;
- **eficiența administrativă** – eliminarea documentelor pe hârtie, transmiterea automată a raportărilor, reducerea costurilor;
- **cercetare și sănătate publică** – accesul anonim la date agregate permite analize epidemiologice și evaluarea politicilor sanitare.

Arhitectura unui sistem EHR

Un EHR complet este construit pe o arhitectură stratificată, care asigură separarea clară între datele de bază, logica medicală și aplicațiile de acces.

1. **Nivelul de date (data layer)** – stochează informațiile medicale propriu-zise (rezultate, note, imagini, coduri). Aceste date sunt structurate conform modelelor standardizate (HL7 CDA, FHIR Resources, openEHR).
2. **Nivelul de servicii (logic layer)** – definește regulile de validare, căutare, securitate și interoperabilitate. Aici sunt implementate arhetipurile clinice și modulele de comunicare.
3. **Nivelul de aplicații (presentation layer)** – interfața prin care utilizatorii accesează datele: medici, pacienți, farmaciști, autorități.

Arhitectura **duală**, propusă de CEN/TC 251 și implementată în standardul **EN 13606**, separă:

- **modelul de referință** (structura logică generală a dosarului, comună tuturor domeniilor);
- **arhetipurile clinice** (modele specializate pentru fiecare tip de document – de exemplu, rețetă, raport operator, rezultat de laborator).

Această abordare permite extinderea și adaptarea EHR fără a modifica structura de bază – un principiu esențial pentru interoperabilitate și actualizare continuă.

Structura informațională EHR

EHR conține mai multe categorii de informații, organizate în secțiuni tematice:

- **Date de identificare** – nume, CNP, sex, vârstă, domiciliu, asigurare, medic de familie;
- **Istoric medical** – boli cronice, alergii, intervenții chirurgicale, tratamente de lungă durată;
- **Date de episod** – internări, consultații, investigații, proceduri efectuate;
- **Rezultate paraclinice** – analize de laborator, imagistică, electrocardiograme, etc.;
- **Medicație curentă și istoric de prescripții;**
- **Note clinice** și observații medicale;
- **Date de urgență** – accesibile fără autentificare completă (ex: grupa sanguină, proteze, contraindicații).

Pentru fiecare element se păstrează **metadate**: cine l-a introdus, când, în ce context și cu ce autorizație, asigurând trasabilitatea completă a actului medical.

Modelul românesc – Dosarul Electronic de Sănătate (DES)

În România, **Dosarul Electronic de Sănătate (DES)**, implementat de Casa Națională de Asigurări de Sănătate (CNAS), reprezintă aplicația națională care integrează informațiile medicale ale pacienților din sistemul public.

Arhitectura DES se bazează pe integrarea mai multor surse:

- medicii de familie, spitalele și laboratoarele transmit automat datele medicale prin intermediul **SIUI (Sistemul Informatic Unic Integrat)**;
- portalul pacientului permite accesul individual, pe baza cardului de sănătate și a codului PIN;
- datele se organizează în patru module principale:
 1. *Sumarul de urgență* (grupă sanguină, alergii, boli cronice, dispozitive implantate);
 2. *Istoricul medical și tratamentele*;
 3. *Prescripțiile și rețetele electronice*;
 4. *Rezultatele analizelor și investigațiilor paraclinice*.

Sistemul românesc respectă principiile ISO 18308 și utilizează standarde HL7, însă interoperabilitatea completă între furnizori este încă limitată. Extinderea funcționalităților DES și conectarea sa la infrastructura europeană EHDS reprezintă direcții prioritare.

Funcțiile esențiale ale EHR

Conform specificațiilor **HL7 EHR Functional Model** și **EuroRec Seal**, un sistem EHR matur trebuie să îndeplinească următoarele funcții:

1. **Crearea și actualizarea înregistrărilor** – introducerea și validarea datelor noi;
2. **Căutare și acces** – identificarea rapidă a informațiilor relevante;
3. **Interoperabilitate** – schimb de date cu alte aplicații (LIS, RIS, farmacie);
4. **Suport decizional** – alerte, ghiduri clinice, sugestii automate;
5. **Securitate și confidențialitate** – control pe roluri, jurnal de acces, criptare;
6. **Audit și trasabilitate** – înregistrarea oricărei modificări;
7. **Export și raportare** – către autorități, registre naționale sau cercetare.

Aceste funcții garantează că EHR nu este doar un depozit de date, ci un **instrument activ de lucru clinic**.

Provocări și limite actuale

Implementarea unui EHR performant nu este un proces exclusiv tehnic, ci unul socio-organizațional. Printre principalele provocări se numără:

- rezistența personalului la schimbare și lipsa formării digitale;
- fragmentarea sistemelor informatice locale;
- absența standardelor unitare de date și terminologii clinice;
- probleme de interoperabilitate între furnizorii de software;
- asigurarea confidențialității datelor sensibile și conformarea la GDPR.

Totodată, menținerea calității datelor este o provocare constantă: un sistem informatic este la fel de bun precum datele introduse în el. De aceea, instruirea personalului medical și auditarea periodică a completitudinii datelor sunt esențiale.

Dosarul electronic de sănătate este coloana vertebrală a medicinei digitale. Prin el, informația devine accesibilă, coerentă și reutilizabilă. Un EHR bine implementat asigură continuitatea îngrijirii, reduce riscul medical și creează baza pentru analize epidemiologice și cercetare.

În era interconectivității și a inteligenței artificiale, EHR nu mai este doar un instrument administrativ, ci o **platformă strategică** pentru medicina predictivă, personalizată și participativă. El transformă datele dispersate în **cunoaștere aplicabilă** — punând pacientul în centrul ecosistemului digital al sănătății.

8.4. Interoperabilitatea sistemelor informatice medicale.

Unul dintre cele mai mari avantaje ale digitalizării medicinei este posibilitatea ca informația să circule rapid și sigur între toate instituțiile implicate în îngrijirea unui pacient. Această capacitate poartă numele de **interoperabilitate** și reprezintă abilitatea sistemelor informatice de a comunica între ele, de a interpreta în mod coerent datele primite și de a le utiliza în scopuri clinice sau administrative, fără intervenție manuală.

Într-un spital modern, informația se naște în mai multe locuri simultan. Laboratorul produce rezultate de analize, aparatul CT generează imagini, medicul scrie observațiile clinice, iar farmacia eliberează medicația. Toate aceste date trebuie să ajungă în același dosar electronic de sănătate, indiferent de software-ul utilizat de fiecare departament. Dacă sistemele nu sunt interoperabile, medicul ar trebui să introducă manual valorile primite pe hârtie, cu riscul apariției erorilor. Interoperabilitatea înseamnă tocmai eliminarea acestor bariere și crearea unei rețele comune de înțelegere între aplicații.

Standarde de comunicație și arhitectură

Pentru ca interoperabilitatea să nu rămână doar o intenție tehnică, ea are nevoie de reguli clare, adică de standarde.

Un **standard** este un set documentat de reguli, formate și cerințe care descriu modul unitar în care sistemele informatice trebuie să funcționeze pentru a fi compatibile și sigure. În domeniul sănătății, standardele garantează că datele medicale generate într-un loc pot fi înțelese și utilizate în altul, fără interpretări greșite.

La fel ca obiectivele bine definite, și standardele trebuie să fie **SMART** – *Specifice* (clar delimitate ca scop), *Măsurabile* (evaluabile prin indicatori), *Atingibile* (realizabile în practică), *Relevante* (aliniat la nevoile clinice reale) și *Temporizate* (revizuite periodic pentru a rămâne actuale).

Un standard de interoperabilitate reușit nu este doar tehnic corect, ci și adoptabil: simplu de implementat, coerent semantic și compatibil cu alte norme internaționale.

Un exemplu simplu poate fi relația dintre un spital și un laborator extern. Atunci când medicul solicită analizele, cererea pleacă electronic, iar

laboratorul o primește automat în propriul sistem. După prelucrarea probelor, rezultatele sunt trimise înapoi tot electronic și se atașează direct în dosarul pacientului. Nu este nevoie de nicio foaie de hârtie, nici de reintroducerea datelor. Totul se întâmplă printr-un schimb standardizat de mesaje informatice.

Pentru ca acest dialog să funcționeze, sistemele trebuie să vorbească „aceeași limbă”. În informatică, această limbă comună este definită de standarde.

Un standard utilizat la nivel global, **HL7 (Health Level Seven)**, conține un set de reguli care descrie modul în care se transmit datele medicale între aplicații. HL7 precizează cum se formulează un mesaj electronic care conține, de pildă, un rezultat de laborator sau un raport de externare, astfel încât orice program compatibil să-l poată interpreta corect.

Exemple de standarde europene includ **EN 13606**, **openEHR** și **OMOP**, prezentate mai detaliat mai jos.

Un alt standard esențial este **DICOM**, folosit pentru imagini medicale. Datorită lui, un RMN realizat într-un spital din Timișoara poate fi vizualizat fără probleme într-o clinică din Cluj, chiar dacă aparatele sunt de la producători diferiți. DICOM stabilește nu doar formatul fișierului, ci și modul în care sunt atașate informațiile despre pacient, data examinării și parametrii tehnici ai imaginii.

Aceste standarde constituie fundația Spațiului European al Datelor privind Sănătatea (**EHDS**).

Totuși, a schimba date nu este suficient. Interoperabilitatea reală presupune ca și **semnificația** acelor date să fie aceeași pentru toți. Dacă într-un spital diagnosticul „infarct miocardic” este codificat diferit față de altul, atunci, chiar dacă mesajul ajunge la destinație, informația nu va fi înțeleasă corect. Aici intervin **terminologiile medicale standardizate**, cum sunt **ICD-10** pentru diagnostice sau **LOINC** pentru teste de laborator. Ele funcționează ca un dicționar medical universal, permițând sistemelor din întreaga lume să înțeleagă aceleași concepte clinice.

Un exemplu simplu ilustrează importanța acestei semnificații comune. Imaginați-vă doi medici care vorbesc limbi diferite, dar trebuie să colaboreze la tratamentul aceluiași pacient. Chiar dacă își trimit scrisori perfect redactate, comunicarea va eșua dacă nu există un limbaj medical comun. În lumea

digitală, standardele și terminologiile joacă exact acest rol de traducători universali între sisteme informatice.

În Europa, tendința este de a unifica aceste standarde printr-o arhitectură comună. Inițiativa **FHIR (Fast Healthcare Interoperability Resources)**, dezvoltată tot sub egida HL7, propune o abordare modernă, bazată pe concepte modulare – așa-numitele *resurse*. Fiecare resursă reprezintă o unitate de informație (un pacient, o analiză, o prescripție), care poate fi accesată prin interfețe standardizate (API-uri). Astfel, sistemele pot comunica direct prin internet, fără să fie nevoie de fișiere intermediare.

FHIR face posibil scenariul în care o aplicație mobilă, aprobată de pacient, să poată accesa în siguranță datele sale medicale dintr-un spital sau laborator. Aceasta este direcția spre care evoluează medicina digitală – o rețea deschisă și sigură, în care informația urmează pacientul, nu dosarele de hârtie.

În context european, interoperabilitatea este consolidată prin standarde dedicate schimbului de date clinice.

EN 13606 – dezvoltat de Comitetul European de Standardizare (CEN/TC 251) – adoptat de asemenea ca standard internațional ISO 13606, definește modelul dual al dosarului electronic: un *model de referință* (structura logică generală a datelor) și *arhetipuri clinice* (modele specializate pentru diverse domenii medicale). Această separare permite adaptarea rapidă la noi specialități fără a modifica structura de bază.




Fig. 8.2. Modelul dual EN 13606

Pe baza aceluiași principiu funcționează și **openEHR**, o arhitectură deschisă care oferă un cadru comun pentru crearea, partajarea și validarea arhetipurilor. openEHR este folosit pe scară largă în proiectele naționale de e-sănătate și în cercetare, asigurând interoperabilitatea semantică între aplicații diferite.

De exemplu, într-un sistem bazat pe openEHR, structura unei fișe de consultație cardiologică poate fi reutilizată și adaptată rapid pentru alte specialități.

În domeniul utilizării secundare a datelor, modelul **OMOP (Observational Medical Outcomes Partnership)** permite armonizarea informațiilor clinice provenite din surse eterogene (EHR, registre, baze de date farmaceutice), făcând posibilă compararea și analiza lor la scară europeană.

Împreună, aceste standarde transformă datele disperate în cunoaștere integrată – un fundament esențial pentru Spațiul European al Datelor privind Sănătatea (EHDS).

Interoperabilitatea nu este doar o problemă tehnică, ci și una organizațională și etică. Fiecare instituție are propriile reguli, proceduri și niveluri de acces. Implementarea interoperabilității înseamnă și stabilirea unor acorduri între parteneri: cine poate vizualiza datele, cine le poate modifica și în ce scop. În acest sens, conceptul de **interoperabilitate organizațională** este la fel de important ca cea tehnică.

Un exemplu concret îl oferă colaborarea dintre medicul de familie și spital. Chiar dacă ambele sisteme sunt compatibile tehnic, schimbul de date nu se poate realiza decât dacă există un cadru legal și o procedură clară care să definească modul în care informațiile pot fi partajate cu respectarea confidențialității.

În România, pașii către interoperabilitate s-au făcut prin interconectarea sistemelor naționale: **SIUI**, **DES** (dosarul electronic de sănătate), **prescripția electronică** și **cardul de sănătate**. Deși implementarea nu este încă perfectă, aceste sisteme au demonstrat că schimbul de date între medici, farmacii și casele de asigurări este posibil și aduce beneficii reale.

La nivel european, același principiu se extinde prin **Spațiul European al Datelor privind Sănătatea (EHDS)**, care va permite ca un pacient din România să-și poată accesa dosarul medical și în alt stat membru, în deplină

siguranță. Interoperabilitatea devine astfel un pas spre un spațiu comun al sănătății digitale, în care frontierele administrative nu mai limitează accesul la informație.

În esență, interoperabilitatea este limbajul comun al medicinei moderne. Ea face posibilă colaborarea între oameni, instituții și tehnologii, creând o punte între datele dispersate și actul medical unitar. Fără interoperabilitate, digitalizarea ar însemna doar înlocuirea hârtiei cu un ecran. Cu ea, însă, sistemul de sănătate devine o rețea vie, interconectată, capabilă să ofere îngrijiri continue și personalizate, oriunde s-ar afla pacientul.

Vocabularul medical

Unul dintre obstacolele majore în schimbul de informații medicale nu este tehnologia, ci limbajul. În fiecare zi, medicii folosesc mii de termeni pentru a descrie boli, simptome, tratamente și proceduri. Problema apare atunci când doi profesioniști – sau două sisteme informatice – folosesc cuvinte diferite pentru a desemna același lucru. Pentru ca informația să fie înțeleasă corect, ea trebuie exprimată într-un limbaj comun, precis și standardizat.

Aici intervin **terminologiile medicale**, **clasificările** și **ontologiile**, care formează împreună **vocabularul** controlat al medicinei digitale.

Imaginați-vă că un spital înregistrează diagnosticul „infarct miocardic acut”, altul „IMA”, iar un al treilea „heart attack”. Din punct de vedere clinic, toți se referă la aceeași afecțiune, dar din punct de vedere informatic, aceste înregistrări sunt complet diferite. Un sistem informatic nu „înțelege” sensul medical al cuvintelor, ci doar etichetele atașate datelor. Fără o terminologie standard, aceste informații nu pot fi comparate, analizate sau raportate la nivel național.

De aceea, fiecare boală, procedură sau analiză de laborator trebuie reprezentată printr-un cod unic, universal recunoscut. Codurile funcționează ca un alfabet numeric al medicinei moderne: ele elimină ambiguitatea și permit comunicarea automată între aplicații, spitale și țări.

Sistemele de clasificare și codificare medicale

Primele forme de standardizare a informațiilor medicale au apărut sub forma **sistemelor de clasificare**, menite să grupeze bolile și condițiile de sănătate în categorii logice. Cel mai cunoscut exemplu este **Clasificarea Internațională**

a Maladiilor (ICD), elaborată de Organizația Mondială a Sănătății, care permite compararea uniformă a datelor la nivel global. Pentru a facilita prelucrarea automată și schimbul electronic al informațiilor, acestor concepte li s-au asociat **coduri unice**, formate din combinații de litere și cifre, dând naștere **sistemelor de codificare medicală** — o etapă esențială în evoluția standardizării datelor clinice.

În prezent, sistemul folosit în România și în majoritatea țărilor europene este **ICD-10**, care cuprinde peste 14.000 de coduri, grupate pe aparate și sisteme. De exemplu, codul *I21.0* desemnează „infarct miocardic acut al peretelui anterior”, iar *J18.9* desemnează „pneumonie nespecificată”.

ICD nu servește doar pentru diagnostic, ci și pentru raportarea cazurilor, analiza statistică și finanțarea serviciilor medicale. Spitalele transmit către casele de asigurări codurile ICD aferente fiecărui episod de îngrijire, iar acestea determină grupa de diagnostic DRG și, implicit, costul rambursat.

În medicina de familie se folosește o clasificare mai simplă, **ICPC-2 (International Classification of Primary Care)**, care acoperă principalele motive de prezentare și intervenții în medicina primară.

Pentru proceduri chirurgicale, există versiuni extinse precum **ICD-10-AM** sau **OPS (Operationen- und Prozedurenschlüssel)** în Germania.

Codificările specializate

Pe măsură ce domeniile medicale s-au diversificat, au apărut și codificări specializate. În farmacologie, **ATC (Anatomical Therapeutic Chemical Classification)** clasifică medicamentele după organul-țintă și mecanismul de acțiune. În laborator, testele și analizele sunt descrise prin **LOINC (Logical Observation Identifiers Names and Codes)**, care asigură recunoașterea unitară a parametrilor biologici, indiferent de furnizorul analizelor.

De exemplu, un test pentru glicemie are același cod LOINC (*2345-7*), indiferent dacă este efectuat în Timișoara sau în Stockholm. Astfel, rezultatele pot fi integrate în mod automat în dosarul pacientului fără confuzii.

Un exemplu frecvent întâlnit în practica spitalicească este sistemul **DRG (Diagnosis Related Groups)**. El nu clasifică bolile în sens strict medical, ci organizează cazurile de internare în funcție de diagnostic, tratamentele

efectuate și resursele utilizate. Scopul său este mai ales **economic și managerial** – să permită evaluarea costurilor și compararea performanței între spitale, păstrând totodată legătura cu clasificările clinice precum ICD.

Aceste codificări formează infrastructura semantică a sistemelor informatice medicale. Ele nu se adresează doar calculatoarelor, ci și oamenilor: oferă o bază comună de înțelegere între specialități și între țări.

Terminologiile extinse – SNOMED CT și UMLS

Un pas mai departe îl reprezintă **terminologiile extinse**, care nu doar clasifică, ci și descriu conceptele medicale prin relațiile dintre ele. Cea mai completă este **SNOMED CT (Systematized Nomenclature of Medicine – Clinical Terms)**, care conține peste 350.000 de concepte clinice.

SNOMED nu este doar o listă de cuvinte, ci o rețea logică: ea știe că „infarctul miocardic” este o formă de „boală ischemică cardiacă”, care afectează „mușchiul inimii” și este asociată cu „durere toracică” și „creșterea troponinei”. Această structură de relații permite sistemelor informatice să „înțeleagă” contextul medical, nu doar textul.

Un alt instrument important este **UMLS (Unified Medical Language System)**, dezvoltat de Biblioteca Națională de Medicină a SUA, care conectează între ele mai multe vocabulare – ICD, SNOMED, LOINC, MeSH – facilitând maparea automată între sisteme diferite.

Prin aceste rețele semantice, un calculator poate identifica echivalențele dintre termeni și poate răspunde la întrebări complexe, precum: „Care sunt bolile infecțioase respiratorii asociate febrei și tusei?” – o sarcină imposibilă pentru o bază de date fără semantică.

Ontologiile medicale

Ontologiile reprezintă o etapă evolutivă a terminologiilor. Ele definesc nu doar conceptele, ci și **relațiile** dintre ele, într-o formă logică, interpretabilă de algoritmi. Într-o ontologie medicală, fiecare termen este un nod într-o rețea care descrie structura cunoașterii clinice: simptome, cauze, localizări, tratamente, interacțiuni.

ONTOLOGY




Fig. 8.3. Relația Ontologie – Arhetip

O modalitate intuitivă de a înțelege rolul ontologiilor este să privim exemplul „**Blood Pressure**” din figura de mai sus (Fig. 8.3).

Într-o **ontologie**, conceptele sunt organizate ierarhic și semantic — „Blood Pressure” este un tip de „Arterial Pressure”, care la rândul său aparține domeniului „Intra-vascular Pressure”. Fiecare concept are relații de tip *has phase*, *has unit*, *applies to* sau *taken with*, care leagă presiunea de ciclul cardiac, unitățile de măsură (mmHg), poziția corpului sau dimensiunea manșetei. Ontologia definește deci *ce există* și *cum se leagă între ele conceptele* într-un model universal al domeniului medical.

Pornind de la această bază largă, se poate construi un **arhetip** — o structură concretă și aplicabilă unui anumit context clinic. În exemplul din dreapta, arhetipul „Blood Pressure” reține doar conceptele necesare unei înregistrări clinice: valorile sistolică și diastolică, poziția corpului și dimensiunea manșetei.

Legătura dintre cele două niveluri este esențială: arhetipul este un **subset derivat din ontologie**, ușor de modificat sau extins fără a altera modelul de referință. Astfel, dacă într-un viitor standard se adaugă o nouă relație (de exemplu, *measured after exercise*), aceasta poate fi inclusă în arhetip fără a afecta structura generală a ontologiei.

În practică, ontologiile asigură **coerenţa semantică** între aplicaţii, iar arhetipurile permit **flexibilitate clinică** şi actualizare rapidă — o combinaţie care face posibilă interoperabilitatea reală a datelor medicale.

Aceste relaţii între concepte pot fi folosite de programele de suport decizional pentru a sugera investigaţii, pentru a anticipa complicaţii sau pentru a detecta inconsecvenţe în datele pacientului. În prezent, multe astfel de ontologii sunt dezvoltate în format deschis, folosind instrumente precum **Protégé** (Stanford University) şi sunt disponibile prin platforme ca **BioPortal** sau **Ontology Lookup Service**.

Un exemplu simplu de **interogare semantică** ilustrează puterea acestor ontologii. Să presupunem că dorim să identificăm toate bolile respiratorii infecţioase asociate simptomelor de *tuse* şi *febră*. O interogare SPARQL asupra ontologiei **SNOMED CT** ar putea formula cererea astfel:

```
SELECT ?boala WHERE {
  ?boala rdf:type SNOMED:InfectiousRespiratoryDisease .
  ?boala SNOMED:hasSymptom SNOMED:Cough . ?boala SNOMED:hasSymptom
  SNOMED:Fever . }
```

Rezultatul ar include termeni precum *gripă*, *bronşită virală* sau *COVID-19*. Astfel de interogări nu caută doar potriviri de text, ci relaţii logice între concepte, permiţând aplicaţiilor clinice să descopere automat asocieri relevante între simptome, diagnostice şi tratamente.

Integrarea şi maparea terminologiilor

În realitate, nicio instituţie medicală nu foloseşte o singură clasificare. Sistemele clinice, de laborator, farmaceutice şi administrative au fiecare propriile codificări. De aceea, este necesară o **mapare** între aceste vocabulare, astfel încât conceptele echivalente să poată fi recunoscute automat. De exemplu, un cod ICD-10 pentru „diabet zaharat de tip 2” trebuie asociat cu conceptul corespunzător din SNOMED CT şi cu testele LOINC relevante (glicemie, HbA1c). Această corespondenţă permite analiza integrată a datelor clinice, de laborator şi de tratament într-un singur cadru logic.




Fig. 8.4. Niveluri de clasificare și granularitate semantică în medicina digitală

În procesul de mapare semantică apare frecvent **dilema intrărilor și ieșirilor informaționale**. Datele clinice detaliate, codificate prin terminologii extinse precum **SNOMED CT**, reprezintă *intrări* pentru sistemele de raportare și analiză epidemiologică bazate pe clasificări precum **ICD-10** sau **ICPC**. Odată agregate, aceste clasificări devin la rândul lor *ieșiri* către nivelul macro — statistică, planificare și politici de sănătate.

Figura 8.4 arată această relație bidirecțională: informația curge de jos în sus, prin sinteză și generalizare, dar și invers, atunci când rezultatele analizei populaționale ghidează practica clinică.

Această tranziție nu este neutră: la fiecare pas se pierd detalii semantice, iar procesul de mapare implică decizii de interpretare. A înțelege cum se realizează conversia între vocabularul clinic (SNOMED) și cel statistic (ICD) înseamnă a înțelege esența interoperabilității – transformarea datelor individuale în cunoaștere colectivă.

Standardizarea limbajului medical nu este o simplă formalitate informatică. Ea are consecințe directe asupra siguranței pacientului. Un diagnostic introdus greșit sau neuniform poate duce la tratamente eronate, statistici false sau decizii administrative incorecte.

În același timp, limbajul controlat permite o mai bună transparență și comparabilitate a datelor, ceea ce este esențial pentru cercetare și politici publice. De exemplu, incidența reală a cancerului colorectal într-o regiune

poate fi evaluată corect doar dacă toate cazurile sunt codificate după aceleași reguli.

Terminologiile, clasificările și ontologiile medicale formează limbajul universal al medicinei digitale. Ele asigură ca un „diagnostic” să însemne același lucru peste tot, indiferent de limbă, specialitate sau sistem informatic.

Fără acest limbaj comun, interoperabilitatea tehnică ar fi inutilă – sistemele ar putea comunica între ele, dar nu s-ar înțelege. Cu el, însă, datele devin informație inteligibilă, reutilizabilă și sigură. Într-o lume medicală tot mai conectată, aceste standarde sunt esențiale pentru o medicină coerentă, bazată pe dovezi și centrată pe pacient.

8.5. Spațiul European al Datelor privind Sănătatea (EHDS)

Pe măsură ce medicina devine tot mai dependentă de date, a apărut o întrebare esențială: cum pot fi folosite informațiile medicale generate în fiecare zi, în mod sigur, eficient și echitabil, nu doar pentru tratamentul individual al pacienților, ci și pentru progresul medicinei la nivel colectiv? Răspunsul Uniunii Europene la această întrebare este inițiativa **Spațiului European al Datelor privind Sănătatea**, cunoscută sub acronimul **EHDS (European Health Data Space)**.

EHDS reprezintă una dintre cele mai ambițioase inițiative europene în domeniul sănătății digitale. Scopul său este să creeze un **cadru comun pentru partajarea, accesarea și utilizarea datelor medicale** în întreaga Uniune, într-un mod sigur, standardizat și orientat spre pacient. Cu alte cuvinte, să transforme datele de sănătate dintr-o resursă locală, fragmentată, într-un **bun public european**, disponibil pentru îngrijire, cercetare și inovare.

Premisele și motivația EHDS

În prezent, sistemele de sănătate din Europa sunt foarte diferite între ele. Fiecare țară are propriile standarde, platforme și niveluri de digitalizare. Un pacient român care se tratează în Franța sau Italia nu are, de regulă, posibilitatea de a-și accesa dosarul medical într-o formă unitară, iar medicul din alt stat nu poate vizualiza istoricul său clinic.

Această fragmentare a devenit o problemă tot mai evidentă în timpul pandemiei de COVID-19, când nevoia de schimb rapid de date medicale între

state a fost vitală. EHDS s-a născut din această lecție: informațiile medicale trebuie să circule la fel de liber ca pacienții și medicii din spațiul european.

Structura și obiectivele EHDS

EHDS are o structură dublă, care reflectă cele două moduri în care pot fi utilizate datele medicale:

1. Utilizarea primară a datelor – pentru îngrijirea directă a pacientului.

Aceasta înseamnă că orice cetățean al Uniunii Europene trebuie să aibă dreptul să-și acceseze propriile date de sănătate, indiferent unde se află, și să le poată partaja în siguranță cu medicii săi.

În practică, acest lucru va fi posibil prin infrastructura **MyHealth@EU**, care interconectează sistemele naționale de dosar electronic (EHR) și prescripție electronică. De exemplu, un pacient român aflat în Portugalia va putea ridica o rețetă emisă în țară sau va permite unui medic local să-i consulte istoricul alergiilor și tratamentele recente.

2. Utilizarea secundară a datelor – pentru cercetare, inovare, politici publice și sănătate publică. În acest caz, datele nu mai sunt folosite pentru un pacient anume, ci pentru analiza unor tendințe, testarea eficienței tratamentelor sau dezvoltarea de noi medicamente. Aceste date vor fi disponibile, în formă anonimată și controlată, prin infrastructura **HealthData@EU**.

Aici, accentul este pus pe **protecția datelor personale**, prin mecanisme stricte de guvernare și audit. Accesul la aceste date va fi permis doar instituțiilor acreditate și în scopuri justificate (de exemplu, studii clinice, cercetare epidemiologică sau evaluarea siguranței tratamentelor).

Standardizare și interoperabilitate europeană

Pentru ca schimbul de date să funcționeze între statele membre, EHDS impune adoptarea **standardelor comune de interoperabilitate**. Acestea includ:

- formatul european al dosarului electronic de sănătate (bazat pe **HL7 FHIR**, **SNOMED CT** și **LOINC**);
- utilizarea terminologiilor medicale uniforme pentru diagnostice, proceduri și rezultate;

- protocoale sigure de autentificare și acces (identitate digitală europeană).

Astfel, un fișier medical creat la Cluj va putea fi înțeles imediat de un sistem din Viena sau Madrid, fără traduceri suplimentare. Informațiile păstrează același sens clinic, indiferent de limba sau infrastructura folosită.

În plus, EHDS promovează **portabilitatea datelor**, adică dreptul fiecărui pacient de a-și descărca și transfera propriul dosar medical între furnizori. Această filozofie este în acord cu principiile **GDPR**, care consideră datele de sănătate ca fiind proprietatea persoanei, nu a instituției.

Guvernanță și securitate

O astfel de rețea europeană necesită un cadru strict de control și protecție. EHDS introduce ideea de **autoritate națională pentru datele de sănătate**, care va superviza modul de acces și utilizare a informațiilor medicale.

Datele sunt criptate, anonimizate și pot fi accesate doar pe bază de autorizație temporară, cu scop clar definit. Fiecare utilizator este urmărit printr-un jurnal de acces, iar orice încercare de utilizare neautorizată este sancționată.

În același timp, EHDS garantează **transparența față de pacient**: oricine va putea vedea cine i-a accesat datele și în ce scop. În acest fel, încrederea publicului devine o componentă centrală a sistemului, fără de care nicio infrastructură digitală nu poate funcționa.

Pentru România, EHDS aduce atât oportunități, cât și provocări. Sistemul actual – format din **SIUI**, **DES**, **rețeta electronică** și **cardul de sănătate** – reprezintă o bază solidă, dar fragmentată. Pentru alinierea la cerințele europene, aceste componente trebuie modernizate și integrate prin interfețe **FHIR** și standarde comune.

Participarea la MyHealth@EU va permite pacienților români să-și acceseze datele medicale oriunde în Uniunea Europeană și va facilita colaborarea între furnizorii de servicii medicale transfrontaliere. În același timp, HealthData@EU va deschide calea pentru cercetarea biomedicală europeană comună, în care și universitățile românești vor putea contribui cu date anonimizate, respectând cele mai înalte standarde de etică și protecție a datelor.

O nouă viziune asupra datelor medicale

EHDS marchează o schimbare de paradigmă: trecerea de la o viziune „instituțională” la una **orientată spre pacient și cunoaștere**. Datele medicale nu mai sunt doar fișiere pasive, stocate în arhivele spitalelor, ci devin o resursă activă, reutilizabilă pentru diagnostic, prevenție, cercetare și inovație.

Un dosar electronic de sănătate nu mai aparține unui singur sistem, ci devine o parte dintr-un ecosistem european al datelor. Această viziune se aliniază cu obiectivele mai largi ale Uniunii Europene – o **Europă a sănătății digitale**, în care frontierele administrative nu mai limitează accesul la îngrijiri și informație.

Pentru viitorii medici, acest concept va schimba fundamental modul de lucru. În locul dosarelor locale, ei vor interacționa cu platforme integrate, vor colabora cu colegi din alte țări și vor putea utiliza instrumente de analiză bazate pe inteligență artificială, antrenate pe baze de date comune.

Spațiul European al Datelor privind Sănătatea nu este doar o inițiativă tehnologică, ci un proiect de civilizație digitală. El propune o Europă în care cunoașterea medicală se construiește împreună, iar datele fiecărui pacient contribuie, indirect, la sănătatea tuturor.

Pentru studenții și profesioniștii de mâine, înțelegerea EHDS înseamnă a înțelege viitorul medicinei: o medicină colaborativă, bazată pe date, transparentă și profund umană.

8.6. Securitatea și protecția datelor în sistemele informatice medicale

Într-o lume medicală tot mai digitalizată, datele pacientului devin o resursă la fel de prețioasă ca medicamentele sau echipamentele. Ele pot salva vieți, dar, folosite greșit, pot provoca daune grave. De aceea, securitatea și protecția datelor sunt printre cele mai sensibile componente ale sistemelor informatice medicale.

În practica informatică este utilă distincția dintre **securitatea datelor** și **protecția datelor**.

- *Securitatea* vizează prevenirea **accesului sau modificării intenționate** a datelor – atacuri informatice, furturi de identitate, sabotaj. Este domeniul apărării active: autentificare, criptare, control al accesului, audit.
- *Protecția*, în schimb, urmărește evitarea **alterării, pierderii sau divulgării neintenționate** a datelor – cauzate de erori umane, defecțiuni tehnice sau procese organizaționale slabe. Ea implică politici de backup, instruirea personalului și evaluarea periodică a riscurilor.

Cele două dimensiuni sunt complementare: un sistem poate fi sigur din punct de vedere tehnic, dar lipsit de protecție organizațională, ceea ce îl face vulnerabil în mod practic.

Spre deosebire de alte tipuri de informații personale, datele medicale vorbesc despre cele mai intime aspecte ale unei persoane – sănătatea, vulnerabilitățile, comportamentele, chiar predispozițiile genetice. Ele pot influența decizii sociale, financiare sau profesionale. O breșă de securitate într-un spital nu înseamnă doar pierderea unor fișiere, ci o încălcare a încrederii dintre pacient și sistemul medical.

Exemplele din ultimii ani arată că atacurile cibernetice asupra spitalelor nu sunt ipotetice. În mai multe țări europene, inclusiv România, atacatorii au blocat servere medicale, solicitând răscumpărări pentru a decipta datele pacienților. În alte cazuri, informațiile furate au fost vândute pe internet.

De aceea, securitatea cibernetică în sănătate nu mai este o chestiune tehnică, ci una de **etică profesională și siguranță a pacientului**.

Principii de bază

În toate domeniile informatice, dar mai ales în sănătate, protecția datelor se bazează pe trei principii fundamentale, cunoscute sub acronimul **CIA: confidențialitate, integritate și disponibilitate**.

Confidențialitatea înseamnă că informația este accesibilă doar persoanelor autorizate. De exemplu, rezultatele unei analize medicale pot fi vizualizate de medicul curant și de pacient, dar nu de alți angajați ai spitalului.

Integritatea se referă la menținerea datelor exacte și nemodificate. Un rezultat de laborator nu trebuie fie alterat accidental sau intenționat. Orice modificare trebuie înregistrată, împreună cu identitatea persoanei care a efectuat-o.

Disponibilitatea asigură accesul la informații atunci când sunt necesare. Chiar dacă sistemul este perfect securizat, el devine inutil dacă un medic nu poate accesa datele unui pacient în timpul unei urgențe.

Cele trei principii trebuie să rămână în echilibru: o protecție excesivă care blochează accesul poate fi la fel de dăunătoare ca lipsa protecției.

Cadrul legal – GDPR și responsabilitățile instituțiilor medicale

În Uniunea Europeană, protecția datelor personale este reglementată prin **Regulamentul General privind Protecția Datelor (GDPR)**, aplicabil din 2018. Acesta consideră **datele de sănătate** o categorie specială, care beneficiază de protecție suplimentară.

GDPR acordă pacientului o serie de **drepturi** clare:

- dreptul de a ști ce date sunt colectate și în ce scop;
- dreptul de a le accesa și corecta;
- dreptul de a le transfera către alt furnizor de servicii medicale (portabilitate);
- dreptul de a solicita ștergerea lor („dreptul de a fi uitat”) atunci când nu mai sunt necesare.

Instituțiile medicale, în schimb, au obligația de a obține **consimțământul explicit** al pacientului pentru prelucrarea datelor și de a implementa măsuri tehnice și organizatorice adecvate. În fiecare spital trebuie să existe un **responsabil cu protecția datelor (DPO)**, care supraveghează respectarea regulilor GDPR.

 *Un exemplu simplu:* dacă un spital dorește să folosească datele pacienților pentru un studiu științific, trebuie să anonimizeze informațiile și să obțină acordul informat al participanților. Nerespectarea acestor reguli poate atrage sancțiuni severe, dar, mai important, poate distruge încrederea publicului.

Măsuri tehnice de protecție

Dincolo de cadrul legal, securitatea depinde de implementarea corectă a măsurilor tehnice. Într-un sistem informatic medical, fiecare pas – de la introducerea datelor până la transmiterea lor prin rețea – trebuie protejat.

Autentificarea utilizatorilor se face, de regulă, pe baza unui nume de utilizator și a unei parole complexe, dar tot mai des sunt folosite metode avansate:

semnătura electronică, cardurile cu cip (cum este **cardul național de sănătate**) sau autentificarea multifactor (parolă + cod SMS sau amprentă).

Controlul accesului este esențial: medicul are acces la datele pacienților săi, farmacistul doar la rețete, iar personalul administrativ doar la informațiile financiare.

Criptarea datelor – atât în timpul stocării, cât și la transmitere – face ca informațiile să devină indescifrabile pentru oricine nu deține cheia de acces.

Auditul sistemului asigură trasabilitatea: fiecare acces sau modificare este înregistrată, permițând identificarea rapidă a unei breșe.

În plus, sistemele informatice trebuie să fie protejate prin **firewall-uri**, **antivirus**, **copii de siguranță (backup)** și **actualizări periodice**, pentru a preveni vulnerabilitățile.

 *Exemplu clinic:* într-un spital, un atac informatic de tip ransomware poate bloca accesul la fișierele pacienților. Dacă există copii de rezervă actualizate și izolate de rețeaua principală, sistemul poate fi restaurat rapid, evitând întreruperea activității.

Confidențialitatea în practica medicală

Securitatea informatică nu înlocuiește obligația etică a confidențialității medicale, ci o extinde în mediul digital. Principiul confidențialității, existent încă din jurământul lui Hipocrate, rămâne la fel de actual: medicul nu are voie să dezvăluie informațiile pacientului fără consimțământul acestuia.

În era electronică, această responsabilitate se extinde la toate formele de date: fișiere digitale, imagini, conversații prin e-mail sau mesagerie medicală. De exemplu, transmiterea unei radiografii printr-o platformă necriptată sau stocarea fișelor pe un dispozitiv personal pot constitui încălcări ale confidențialității.

Educația digitală a personalului medical este, prin urmare, esențială. Oricât de avansat ar fi un sistem, **cea mai slabă verigă rămâne omul** – parola scrisă pe un bilețel, laptopul pierdut sau documentul uitat pe ecran pot compromite întregul sistem.

Tehnologii emergente – blockchain și securitatea distribuită

În ultimii ani, tot mai multe inițiative explorează utilizarea tehnologiei **blockchain** în protecția datelor medicale. Blockchain-ul funcționează ca un **registru digital descentralizat**, adică o bază de date împărțită între numeroase calculatoare dintr-o rețea. Fiecare nouă informație adăugată – numită *bloc* – conține nu doar datele proprii, ci și o amprentă criptografică (*hash*) a blocului anterior. Prin această legătură, toate blocurile formează un „lanț” continuu și sigur: dacă cineva încearcă să modifice un bloc, întreaga secvență devine invalidă și modificarea este respinsă de celelalte noduri din rețea (fig. 8.6).




Fig. 8.6. Lanț de blocuri în rețea distribuită – fiecare bloc conține hash-ul celui anterior

În domeniul sănătății, o astfel de structură poate asigura **trasabilitatea completă a datelor medicale**: orice acces, modificare sau transfer este înregistrat automat, iar integritatea înregistrărilor poate fi verificată în orice moment. Pacientul ar putea controla direct cine îi vizualizează informațiile, printr-un mecanism de consimțământ digital, și ar fi notificat dacă datele sale sunt consultate sau transmise.

De asemenea, blockchain-ul poate fi utilizat pentru **gestionarea consimțământului informat**, pentru **verificarea autenticității medicamentelor în lanțul de aprovizionare**, sau pentru **transferul securizat de date între spitale și centre de cercetare**, fără un intermediar central.

Deși implementarea sa în sistemele de sănătate este încă experimentală, blockchain-ul oferă o perspectivă promițătoare: o **medicină digitală distribuită**, mai sigură, transparentă și centrată pe pacient. Spre deosebire de

blockchain-urile **publice**, folosite în domeniul criptomonedelor și accesibile oricui din rețea, în sănătate se utilizează de regulă **blockchain-uri private sau permisionate**. Acestea limitează accesul la instituțiile medicale și actorii autorizați, combinând avantajele transparenței și securității cu respectarea normelor stricte de confidențialitate impuse de legislația sanitară și de protecția datelor (GDPR).

Echilibrul dintre protecție și acces

Securitatea datelor medicale nu trebuie privită ca o barieră, ci ca o garanție a încrederii. Un sistem prea rigid, care restricționează accesul medicilor la informații, poate încetini actul medical și pune pacienții în pericol. În schimb, un sistem prea permisiv devine vulnerabil.

Provocarea reală este de a găsi un echilibru între protecție și utilitate: informațiile trebuie să fie în siguranță, dar și disponibile acolo unde sunt necesare, în timp real.

Protecția datelor medicale este fundamentul medicinei digitale. Fără încrederea pacienților că informațiile lor sunt păstrate în siguranță, niciun sistem informatic, oricât de performant, nu poate funcționa.

Pentru medicii de mâine, cunoașterea principiilor de securitate informatică devine o componentă a profesionalismului medical. Nu este suficient să știi să interpretezi un rezultat; trebuie să știi și cum să-l protejezi.

Așa cum jurământul medical cere respectarea vieții și demnității pacientului, epoca digitală adaugă o nouă datorie: **protejarea datelor sale**, pentru ca încrederea în medicină să rămână deplină și în universul electronic.

8.7. Direcții de dezvoltare

Sistemele informatice medicale au evoluat rapid în ultimele decenii, de la aplicații izolate de gestiune administrativă la platforme integrate care interconectează spitale, laboratoare, farmacii și autorități de sănătate publică. Astăzi, ele formează infrastructura invizibilă care susține întreaga activitate medicală modernă. Dar, pe măsură ce tehnologia avansează, apar și noi provocări, legate de calitate, interoperabilitate, etică și inteligență artificială.

Înțelegerea direcțiilor de dezvoltare ale acestor sisteme este esențială pentru medicul de mâine, care nu va mai lucra doar cu pacienți, ci și cu date, algoritmi și platforme digitale interconectate.

De la informatizare la inteligență clinică

Timp de mulți ani, scopul principal al informatizării în sănătate a fost automatizarea activităților repetitive: introducerea datelor, generarea rețetelor, raportarea cazurilor sau arhivarea documentelor. Această etapă a adus eficiență administrativă, dar nu a schimbat radical modul de gândire medical.

Astăzi, sistemele informatice intră într-o nouă etapă – cea a **inteligenței clinice integrate**. Dosarul electronic al pacientului (EHR) nu mai este doar un registru de date, ci un instrument de sprijin decizional, capabil să analizeze informațiile în timp real și să ofere recomandări bazate pe dovezi.

 *De exemplu*, un sistem EHR modern poate semnaliza automat interacțiuni medicamentoase periculoase, poate avertiza medicul asupra valorilor anormale recente sau poate sugera investigații suplimentare conform ghidurilor clinice. Aceste funcții de **Clinical Decision Support (CDS)** reprezintă pasul de la informare la asistență decizională – o tranziție care transformă datele în cunoaștere utilă.

Integrarea inteligenței artificiale

Inteligența artificială (IA) a început deja să influențeze toate componentele sistemelor informatice medicale. Algoritmii de **machine learning** pot analiza volume uriașe de date din EHR-uri, imagini, semnale biologice și texte medicale pentru a identifica modele greu de observat de către om.

În radiologie, IA poate detecta leziuni pulmonare sau fracturi subtile cu o acuratețe comparabilă cu cea a specialiștilor. În cardiologie, rețelele neuronale pot interpreta electrocardiograme complexe, anticipând riscul de aritmie. În domeniul sănătății publice, modelele predictive pot estima evoluția unei epidemii pe baza datelor în timp real.

Integrarea acestor instrumente în sistemele informatice spitalicești presupune însă respectarea unor criterii stricte de **calitate, transparență și responsabilitate**. Un algoritm nu poate fi considerat „medic digital”, ci un **asistent** care oferă sugestii pe baza datelor disponibile. Decizia finală rămâne în mâinile profesionistului uman.

Calitatea și certificarea sistemelor informatice medicale

Pe măsură ce rolul acestor sisteme devine tot mai critic, evaluarea **calității** lor nu mai este un detaliu tehnic, ci o cerință fundamentală. Un sistem informatic medical trebuie să fie **sigur, fiabil, interoperabil și ușor de utilizat**.

Calitatea unui sistem nu se referă doar la absența erorilor, ci și la modul în care sprijină activitatea medicală. Interfața trebuie să fie intuitivă, pentru a evita introducerea greșită a datelor. Timpul de răspuns trebuie să fie rapid, pentru a permite utilizarea în urgențe. Accesul la informație trebuie să fie complet și clar structurat.

La nivel european, aceste criterii sunt definite de organizații precum **EuroRec** și **HL7 International**, care oferă modele de certificare pentru sistemele EHR. Printre cerințele principale se numără:

- respectarea standardelor de interoperabilitate (HL7, DICOM, FHIR);
- conformitatea cu regulile de securitate și confidențialitate (GDPR, ISO 27001);
- trasabilitatea completă a acțiunilor utilizatorilor;
- auditarea periodică a funcționării sistemului.

În România, aceste principii devin din ce în ce mai relevante pe măsură ce spitalele adoptă sisteme informatice complexe. Verificarea calității nu este doar o obligație legală, ci o condiție pentru siguranța pacientului. Un sistem care se blochează în timpul unei urgențe, care dublează datele sau care nu protejează corect informațiile poate avea consecințe grave, atât clinice, cât și etice.

Arhitecturi distribuite și cloud medical

O altă direcție de dezvoltare este migrarea către **infrastructuri distribuite**, bazate pe servicii în cloud. În loc ca fiecare spital să dețină propriile servere, datele pot fi stocate și prelucrate în centre securizate, cu disponibilitate continuă și capacitate de actualizare automată.

Această abordare reduce costurile de întreținere și facilitează accesul rapid la informații, indiferent de locație. De exemplu, un medic de familie poate consulta investigațiile efectuate într-un spital universitar, fără a mai solicita copii fizice.

Totuși, cloud computing-ul medical impune condiții stricte de securitate și conformitate legală. Datele trebuie criptate, serverele amplasate în spații conforme cu reglementările europene, iar accesul controlat riguros.

În perspectivă, se prefigurează o arhitectură **hibridă**, în care datele curente ale pacientului sunt accesibile rapid în cloud, iar arhivele istorice sunt păstrate local, pentru redundanță și siguranță.

Interoperabilitate extinsă și EHDS

O direcție strategică majoră este extinderea interoperabilității dincolo de granițele naționale, prin **Spațiul European al Datelor privind Sănătatea (EHDS)**. În următorii ani, sistemele EHR ale fiecărui stat vor fi conectate într-o rețea comună, bazată pe standarde deschise precum HL7 FHIR.

Aceasta va permite pacienților să acceseze datele lor medicale oriunde în Uniunea Europeană și va facilita colaborarea între medici, cercetători și autorități de sănătate publică. În acest context, calitatea sistemelor informatice nu se mai măsoară doar prin performanța tehnică, ci și prin **capacitatea de a colabora și de a genera valoare comună**.

Etica și responsabilitatea în era digitală

Pe măsură ce sistemele informatice devin mai inteligente și mai autonome, apare o nouă dimensiune – cea etică. Cine este responsabil atunci când un algoritm greșește? Cum se asigură echitatea și transparența în deciziile asistate de AI? Cum se protejează libertatea pacientului într-un univers dominat de date?

Răspunsurile la aceste întrebări nu pot veni doar din tehnologie, ci dintr-o **cultură digitală medicală responsabilă**, care combină competența profesională cu respectul pentru demnitatea umană. În acest sens, pregătirea viitorilor medici trebuie să includă nu doar cunoștințe clinice, ci și o înțelegere profundă a eticii și securității în utilizarea datelor digitale.

Evoluția sistemelor informatice medicale reflectă transformarea medicinei însăși – dintr-o disciplină empirică într-una bazată pe date, standarde și colaborare globală. Înțelegerea acestor principii la nivel de student nu înseamnă doar familiarizare cu tehnologia, ci și formarea unei culturi a responsabilității digitale.

A învăța cum circulă, se protejează și se interpretează datele medicale este primul pas către o practică medicală sigură, transparentă și conectată la Europa digitală a viitorului. Pentru viitorii medici, a înțelege modul în care circulă și se protejează informația medicală înseamnă a deveni parte activă din această transformare.

De reținut

- Sistemele informatice medicale conectează toate nivelurile de asistență într-un ecosistem digital unic.
- EHR este nucleul acestui sistem, asigurând continuitatea îngrijirii și suportul decizional.
- Interoperabilitatea și standardizarea (HL7, DICOM, SNOMED CT, FHIR) sunt condiții esențiale.
- EHDS reprezintă următorul pas european către utilizarea secundară sigură a datelor.
- Securitatea și etica digitală garantează încrederea pacientului și sustenabilitatea sistemului.

Capitolul 9 – Telemedicina

Capitolul anterior a prezentat fundamentele tehnice ale sistemelor informatice medicale – structura datelor, interoperabilitatea și protecția informației. În continuare, telemedicina ilustrează modul în care aceste principii se transformă în practică medicală: actul clinic devine posibil la distanță, prin intermediul datelor digitale care leagă pacientul și medicul într-un spațiu comun al deciziei.

9.1 Definiție, delimitări și context

Telemedicina reprezintă exercitarea actului medical prin intermediul tehnologiilor digitale de comunicație, care permit interacțiunea dintre medic și pacient aflat la distanță. Esența sa rămâne aceeași ca în practica tradițională: stabilirea diagnosticului, recomandarea tratamentului, monitorizarea evoluției sau oferirea unei a doua opinii. Ceea ce se schimbă este mediul — consultația are loc printr-o interfață electronică, iar informația medicală devine fluxul central al actului clinic.



Pentru a evita confuziile frecvente, este importantă delimitarea față de alte concepte înrudite. **Telemedicina** se referă strict la activitățile medicale care implică decizie clinică, responsabilitate profesională și interacțiune între profesioniști autorizați. În schimb, **telesănătatea (telehealth)** include și activități non-clinice, precum educația pentru sănătate, prevenția, formarea profesională sau managementul administrativ. La rândul său, **eHealth** desemnează infrastructura digitală care susține întregul ecosistem: dosare electronice, portaluri pacient, rețele și standarde de interoperabilitate.

Astfel, telemedicina poate fi privită ca o **extensie a actului medical**, nu o alternativă la acesta. Ea aduce posibilitatea de a oferi îngrijiri continue pacienților aflați în zone izolate, de a asigura consulturi interdisciplinare rapide și de a optimiza timpul medicilor specialiști. În același timp, transferul deciziei clinice în mediul virtual ridică întrebări privind validitatea observației, siguranța transmiterii datelor și etica comunicării la distanță — aspecte care vor fi discutate în secțiunile următoare.

Dezvoltarea telemedicinii a fost impulsionată de mai multe valuri tehnologice: progresele rețelilor de bandă largă, apariția dispozitivelor inteligente și a senzorilor portabili, extinderea platformelor cloud și, recent, integrarea inteligenței artificiale. Dacă primele aplicații vizau domenii izolate, cum ar fi **teleradiologia** sau **telepatologia**, astăzi telemedicina este parte a unei **rețele integrate de servicii clinice digitale**, aflate sub reglementare legală în tot mai multe țări.

În România, cadrul legal al telemedicinii a fost stabilit prin **Legea nr. 95/2006 privind reforma în domeniul sănătății** (Titlul XVII), completată în 2022 prin **Hotărârea Guvernului nr. 1133**, care definește principalele tipuri de servicii – teleconsultație, teleexpertiză, teleasistență, telemonitorizare, teleradiologie și telepatologie. Acest cadru confirmă recunoașterea telemedicinii ca formă oficială a actului medical, supusă aceluiași standarde profesionale, deontologice și juridice ca și practica tradițională.

Telemedicina nu trebuie privită ca substitut al medicinei clasice, ci ca **instrument complementar**, menit să extindă accesul, să reducă inegalitățile și să aducă decizia medicală mai aproape de pacient. Ea se înscrie în transformarea mai amplă a sistemelor de sănătate către modele digitale, bazate pe date, interoperabilitate și colaborare transdisciplinară.

9.2 Arhitectura sistemelor de telemedicină

Telemedicina nu este o aplicație singulară, ci o rețea de tehnologii și procese care permit desfășurarea actului medical la distanță. În esență, un sistem de telemedicină integrează trei elemente majore: **utilizatorii (pacientul și medicul)**, **platforma software** care asigură interfața de comunicare și **infrastructura tehnică** prin care se transmit, se stochează și se protejează datele medicale.

Structura generală

La un capăt al sistemului se află pacientul – sursa informației clinice. Acesta poate utiliza un dispozitiv mobil, un senzor purtabil sau un echipament dedicat (de exemplu, un tensiometru conectat sau un dispozitiv ECG portabil). Datele colectate local sunt transmise prin rețea către o platformă centrală, unde sunt procesate, stocate și puse la dispoziția medicului.




Figura 9.1 – Componentele de bază ale infrastructurii de telemedicină

Medicul accesează aceste date printr-un portal securizat sau direct din sistemul informatic al spitalului, acolo unde platforma este integrată cu dosarul electronic al pacientului (**EHR**). Consultația se poate desfășura sincron – prin videoconferință, atunci când medicul interacționează direct cu pacientul –, sau asincronic, când datele sunt analizate ulterior, de exemplu într-un caz de teleexpertiză imagistică.

Între aceste două capete – pacientul și medicul – se află **platforma de telemedicină**, un ansamblu software care asigură fluxul informațional, autentificarea, criptarea și jurnalizarea tuturor operațiunilor. Aceasta comunică prin protocoale standardizate (HL7, FHIR, DICOM Web) și folosește baze de date compatibile cu modelele de interoperabilitate discutate în capitolul precedent (EN 13606, openEHR).

Fluxul datelor

Într-o sesiune tipică de teleconsultație, datele parcurg următorul traseu:

1. **Captare locală** – dispozitivul pacientului colectează parametri fiziologici (ex. tensiune, puls, glicemie).
2. **Transmitere** – informațiile sunt criptate și trimise prin rețea (Wi-Fi, 4G/5G, VPN).
3. **Stocare temporară** – pe serverul aplicației, într-un mediu controlat și auditat.

4. **Acces și interpretare** – medicul vizualizează datele, formulează concluzii și le transmite pacientului.
5. **Arhivare și integrare** – rezultatul este salvat în EHR, devenind parte din istoricul medical.

Fiecare dintre aceste etape presupune standarde și protocoale specifice. De exemplu, **IEEE 11073** definește modul în care dispozitivele medicale portabile comunică între ele, în timp ce **FHIR** facilitează schimbul de date între aplicații diferite (platforme de telemedicină, sisteme de laborator, registre clinice).

Infrastructura tehnologică

Din punct de vedere tehnic, sistemele de telemedicină pot fi:

- **centralizate**, atunci când stocarea și procesarea datelor se fac într-un centru național sau instituțional;
- **distribuite**, când informația rămâne la sursă, iar aplicațiile comunică prin servicii de interoperabilitate;
- sau **hibride**, modelul tot mai adoptat în prezent, bazat pe tehnologii cloud cu control descentralizat al accesului.

Securitatea infrastructurii este garantată prin criptare end-to-end, autentificare multifactor și înregistrarea tuturor accesărilor. Sistemul trebuie să asigure nu doar protecția informației, ci și **continuitatea serviciului**, adică funcționarea neîntreruptă a conexiunilor, chiar în condiții de trafic intens sau rețele instabile.

Conectivitate și fiabilitate

Unul dintre aspectele critice ale telemedicinii este calitatea conexiunii. O întârziere de câteva secunde poate fi neglijabilă într-o teleconsultație generală, dar devine inacceptabilă în telechirurgie. De aceea, infrastructura de comunicație trebuie dimensionată în funcție de scop: în telemonitorizare se pune accent pe siguranța transferului, iar în teleexpertiză – pe fidelitatea imaginilor și latența redusă.

În ultimii ani, evoluția rețelelor **5G** și a platformelor cloud medicale a permis extinderea aplicațiilor către zone rurale sau izolate, democratizând accesul la servicii specializate. Totuși, fiabilitatea tehnică nu înlocuiește competența

profesională: orice sistem de telemedicină rămâne doar o extensie a actului medical, nu un substitut al lui.

9.3 Aplicații clinice reprezentative

Telemedicina nu este o tehnologie singulară, ci o suită de servicii clinice care folosesc mijloace digitale pentru a furniza îngrijiri medicale la distanță. Fiecare specialitate o adoptă în mod diferit, în funcție de tipul de date implicate, de gradul de urgență și de rolul contactului direct dintre medic și pacient.

Teleconsultația

Forma cea mai cunoscută și mai frecvent utilizată este **teleconsultația**, care reproduce structura unei consultații clasice, dar printr-o interfață video sau o platformă dedicată. Ea poate fi realizată între medic și pacient (B2C – *business to consumer*), între doi medici (B2B – *business to business*, sub forma teleexpertizei), sau între echipe multidisciplinare.

În practica din România, teleconsultația este reglementată ca act medical complet, iar documentele rezultate – rețete, bilete de trimitere, recomandări – au valoare juridică echivalentă celor eliberate în format fizic. Cele mai frecvente aplicații sunt în **dermatologie**, **psihiatrie**, **recuperare medicală** și **asistență primară**, domenii unde comunicarea vizuală și anamneza detaliată pot substitui, în mare măsură, examenul clinic direct.



Un exemplu instituțional este platforma de teleexpertiză implementată de **SMURD (Serviciul Mobil de Urgență, Reanimare și Descarcerare)**, care permite consultul în timp real al pacienților aflați în unități mobile de terapie intensivă. Medicii din centrele regionale pot evalua imagini, parametri vitali și rezultate ale analizelor, oferind decizii rapide care scad semnificativ timpul până la intervenție.

Telemonitorizarea pacienților cronici

O altă categorie esențială este **telemonitorizarea**, folosită în bolile cronice care necesită urmărire continuă. Pacientul poartă senzori care înregistrează parametri fiziologici (tensiune arterială, puls, glicemie, saturație în oxigen) și transmit datele automat către platforma medicului curant.



Exemplul clasic este cel al pacienților cu insuficiență cardiacă, unde telemonitorizarea permite detectarea precoce a decompensărilor și ajustarea tratamentului fără internare. În diabet, dispozitivele moderne de monitorizare continuă a glicemiei (CGM) pot trimite în timp real datele către aplicațiile medicului sau ale familiei, generând alerte automate.

Un alt exemplu este cel de telemonitorizare postoperatorie ortopedică, unde senzorii integrați în orteze sau dispozitive de sprijin trimit zilnic informații despre unghiul de flexie, durata sprijinului și frecvența mișcărilor. Aceste date sunt analizate automat și comparate cu valorile așteptate, permițând kinetoterapeutului să ajusteze programul de recuperare fără deplasarea pacientului la clinică.

Teleradiologia și telepatologia

În specialitățile bazate pe imagistică, telemedicina a devenit instrument de rutină. **Teleradiologia** permite transmiterea securizată a imaginilor CT, RMN sau radiografice către centre specializate pentru interpretare, iar **telepatologia** oferă posibilitatea evaluării la distanță a lamelor digitalizate.

Prin standardele **DICOM** și **DICOM Web**, imaginile medicale pot fi comprimate fără pierdere semnificativă de calitate și partajate în câteva secunde. În spitalele care dispun de sisteme PACS integrate, teleradiologia asigură disponibilitatea permanentă a specialiștilor, reducând timpul de diagnostic în urgențe.

În România, astfel de soluții sunt deja utilizate în rețeaua spitalelor de urgență și în unitățile județene unde nu există radiologi permanenți. Teleexpertiza imagistică oferă o a doua opinie în cazurile complexe și sprijină formarea profesională continuă.

Telechirurgia și teleasistența robotică

Cea mai avansată formă de telemedicină este **telechirurgia**, unde gesturile operatorii sunt transmise de la un chirurg aflat la distanță către un robot chirurgical. Deși implementarea sa clinică este limitată de infrastructura de rețea și de costuri, principiul este deja validat: comenzi precise, cu latență sub o secundă, pot fi executate prin conexiuni securizate de mare viteză.

O variantă mai frecvent aplicată este **teleasistența chirurgicală**, când un expert ghidează echipa locală prin sistem video și imagine 3D augmentată. În centrele universitare, astfel de proceduri sunt folosite pentru formare, demonstrații și intervenții complexe în colaborare internațională.

Beneficii și limitări

Aplicarea telemedicinii în practică aduce beneficii evidente – acces mai rapid la specialist, reducerea deplasărilor inutile, continuitatea îngrijirii și scăderea costurilor pentru pacient. Totuși, există și limitări: imposibilitatea efectuării examenului fizic complet, dependența de calitatea conexiunii, riscul de eroare de interpretare și dificultatea stabilirii unei relații empatice autentice.

Telemedicina nu înlocuiește consultația clasică, dar o **completează** acolo unde distanța, timpul sau resursele o fac imposibilă. Ea redefinesc granița dintre prezență fizică și contact digital, păstrând însă esența profesiei medicale – actul de îngrijire, bazat pe cunoaștere, responsabilitate și încredere.

9.4 Cadrul juridic al telemedicinii în România

În România, telemedicina este recunoscută oficial ca **formă de exercitare a actului medical**, având același regim juridic, profesional și deontologic ca activitatea desfășurată în cabinet sau spital. Baza legală o constituie **Legea nr. 95/2006 privind reforma în domeniul sănătății**, completată prin **Hotărârea Guvernului nr. 1133/2022**, care stabilește normele de aplicare și definește tipurile de servicii ce pot fi furnizate prin mijloace electronice.

Potrivit acestor reglementări, telemedicina cuprinde:

- **Teleconsultația**, realizată între medic și pacient;
- **Teleexpertiza**, între doi sau mai mulți medici;

- **Telemonitorizarea**, pentru supravegherea la distanță a pacienților cronici;
- **Teleradiologia și telepatologia**, pentru analiza imaginilor medicale și a probelor biologice transmise digital.

Toate aceste activități trebuie efectuate de profesioniști autorizați, în unități medicale acreditate, cu respectarea aceluiași obligații de confidențialitate și trasabilitate ca în medicina convențională. Medicul rămâne responsabil pentru decizia clinică, indiferent de mediul tehnologic utilizat.

Hotărârea Guvernului nr. 1133/2022 prevede și condițiile tehnice minime: sistemele de telemedicină trebuie să asigure **autentificarea utilizatorilor, criptarea comunicațiilor, înregistrarea accesului la date și stocarea securizată a documentelor medicale**. În plus, furnizorii de servicii sunt obligați să utilizeze aplicații certificate, să păstreze jurnalele operațiunilor și să respecte normele de arhivare electronică.

Pacientul are dreptul de a fi informat în prealabil despre natura și limitele consultației la distanță, despre modul de protejare a datelor sale și despre identitatea medicului, putând în orice moment să solicite întreruperea serviciului medical prestat la distanță. **Consimțământul informat** trebuie exprimat explicit, iar refuzul teleconsultației nu poate limita accesul la îngrijiri medicale prin mijloace tradiționale.

Telemedicina se află la intersecția mai multor domenii de reglementare – sănătate, comunicații, protecția datelor și securitate cibernetică. În acest context, legislația românească se corelează cu directivele europene, în special **Regulamentul general privind protecția datelor (GDPR)** și cadrul de interoperabilitate promovat prin **inițiativa eHDSI (eHealth Digital Service Infrastructure)**. Aceste norme urmăresc compatibilitatea sistemelor și protecția datelor în consultațiile transfrontaliere, sprijinind integrarea României în Spațiul European al Datelor privind Sănătatea.

Prin aceste reglementări, România se aliniază standardelor internaționale, oferind un cadru legal clar care validează telemedicina ca parte integrantă a sistemului de sănătate. Rămâne însă o provocare continuă adaptarea normelor la ritmul inovației tehnologice, pentru ca siguranța juridică și etica medicală să țină pasul cu noile forme de practică digitală.

9.5 Securitate, confidențialitate și fiabilitate

Actul medical desfășurat la distanță presupune un volum mare de date sensibile care circulă între pacient, platformă și medic. Dacă în sistemele informatice clasice aceste date erau protejate în interiorul instituției, telemedicina le expune unui context tehnologic mult mai variat — rețele publice, dispozitive personale și platforme cloud. De aceea, securitatea și confidențialitatea devin condiții de existență ale serviciului, nu doar cerințe tehnice.

Securitatea informațională

Securitatea în telemedicină urmărește prevenirea accesului neautorizat, a modificărilor intenționate și a pierderii de date. Comunicarea dintre pacient și medic trebuie să fie criptată „end-to-end”, iar autentificarea să se facă prin metode multifactoriale. Platformele medicale certificate păstrează un **jurnal electronic al accesărilor (log)**, care permite identificarea oricărei acțiuni asupra datelor: vizualizare, descărcare, modificare sau ștergere.

Transmisia imaginilor radiologice sau a datelor fiziologice în timp real impune protocoale standardizate, cum ar fi **DICOM Web** și **HL7-FHIR over HTTPS**, care asigură criptarea și integritatea pachetelor de date. În centrele unde funcționează servicii de telemonitorizare, conexiunile se realizează prin rețele private virtuale (VPN) sau prin canale securizate dedicate.

Confidențialitatea datelor

Confidențialitatea este protejată de **GDPR**, dar în telemedicină aceasta trebuie dublată de măsuri organizaționale. Personalul medical care participă la teleconsultații trebuie instruit privind gestionarea parolelor, setările de partajare a ecranului și modalitățile de stocare temporară a fișierelor. Pacientul are dreptul de a ști cine îi accesează datele și pentru ce scop, iar fiecare acces trebuie documentat.

În unele platforme moderne, controlul asupra informațiilor este deținut parțial de pacient: acesta poate acorda, suspenda sau retrage accesul medicului la datele sale, iar modificările sunt înregistrate automat în jurnalul sistemului.

Fiabilitatea serviciului

Un domeniu tot mai activ de cercetare este aplicarea tehnologiei blockchain pentru garantarea integrității datelor medicale transmise la distanță. Fiecare acces sau modificare a informațiilor este înregistrată într-un bloc criptografic, distribuit în rețea, imposibil de alterat fără a fi detectat. Astfel, blockchain oferă trasabilitate completă și transparență în fluxurile de telemedicină, sporind încrederea pacientului și siguranța procesului clinic.

Securitatea informației trebuie completată de **fiabilitatea tehnică** a sistemului. Telemedicina nu tolerează întreruperi de conexiune, întârzieri mari sau pierderi de pachete de date. Platformele trebuie să dispună de mecanisme automate de reluare a transmisiei, copiere redundantă a informațiilor și monitorizare a timpilor de răspuns. În telemonitorizarea pacienților critici, orice întrerupere poate avea consecințe clinice, motiv pentru care infrastructura trebuie testată periodic și certificată conform standardelor ISO/IEC 27001 și ISO 27799.

În final, protejarea datelor și asigurarea continuității serviciului nu țin doar de tehnologie, ci și de etica profesiei. Respectarea confidențialității și a integrității actului medical rămâne o responsabilitate comună — a medicului, a instituției și a platformei digitale care mediază contactul cu pacientul.

9.6 Aspecte etice și de comunicare

Telemedicina modifică nu doar locul în care se desfășoară consultația, ci și **modul în care se construiește relația dintre medic și pacient**. Lipsa contactului direct schimbă percepția asupra empatiei, a încrederii și a responsabilității. Dacă medicina tradițională se bazează pe prezența fizică, pe gesturi și expresii, în mediul digital aceste elemente trebuie transpuse prin voce, privire și claritate verbală.

Etica actului medical la distanță

Deși mediul se schimbă, principiile rămân aceleași: competență, confidențialitate, respect pentru autonomia pacientului și integritate profesională. Medicul trebuie să fie conștient de **limitele evaluării la distanță** – ceea ce nu poate observa sau verifica direct – și să comunice transparent aceste limite pacientului. O recomandare făcută fără examinare completă trebuie însoțită de avertismentul că decizia finală poate necesita o evaluare față în față.

Totodată, telemedicina amplifică importanța **consimțământului informat**. Pacientul nu trebuie doar să accepte consultația online, ci să înțeleagă implicațiile: natura comunicării, riscurile tehnice, modul de stocare a datelor și identitatea medicului. Lipsa acestei clarificări poate duce la neînțelegeri sau la pierderea încrederii, chiar dacă actul medical este corect.

Un alt aspect etic important privește **echitatea digitală**. Telemedicina nu trebuie să excludă pacienții fără competențe tehnologice, conexiune stabilă sau echipamente adecvate. În acest sens, obligația morală a medicului este și una socială — aceea de a adapta limbajul și instrumentele pentru a menține accesul echitabil la îngrijiri.

Comunicarea empatică în mediul digital

În lipsa contactului direct, comunicarea trebuie construită deliberat. Tonul vocii, ritmul vorbirii și claritatea explicațiilor cântăresc mai mult decât în întâlnirile față în față. Într-o teleconsultație, tăcerile pot părea mai lungi, iar expresiile faciale pot fi distorsionate de calitatea imaginii. De aceea, medicul trebuie să **verbalizeze empatia**, nu doar să o transmită nonverbal.

Exemple simple, precum „Vă aud îngrijorat” sau „E firesc să aveți această teamă” ajută pacientul să simtă că este înțeles, chiar prin ecran. În același timp, contactul vizual direct (privirea spre cameră, nu spre monitor) și o postură deschisă contribuie la restabilirea senzației de prezență reciprocă.

Conceptul de bedside manner

Prin analogie cu *bedside manner* – arta comportamentului medicului la patul bolnavului – a apărut în ultimii ani termenul de **webside manner**, care desemnează ansamblul de atitudini și abilități necesare pentru o consultație digitală reușită.




Figura 9.2 Exemplu de teleconsultație cu interacțiune vizuală directă.

Autor Intel Free Press, licența CC BY-SA 2.0

Un *webside manner* eficient presupune:

- **pregătirea tehnică** a consultației: verificarea conexiunii, luminii și cadrului vizual;
- **prezentarea clară a identității** și a rolului medicului;
- **stabilirea unei atmosfere de siguranță**, prin ton calm și comunicare atentă;
- **ascultare activă**, cu pauze scurte care lasă pacientul să se exprime;
- **reformularea periodică** („Deci, dacă am înțeles corect, simptomele au apărut ieri...”);
- **încheierea formală**, printr-un sumar verbal al concluziilor și următorilor pași.

În teleconsultațiile cu vârstnici sau pacienți anxioși, aceste gesturi simple înlocuiesc contactul fizic cu **prezența digitală** – un echivalent emoțional al atingerii profesionale.

În formarea viitorilor medici, dezvoltarea *webside manner*-ului devine la fel de importantă ca abilitățile clinice. Este un exercițiu de empatie tehnologică, care cere adaptare și conștientizarea detaliilor aparent minore: modul în care

camera este poziționată, expresia feței în momentele de tăcere, gestul de a privi pacientul când acesta vorbește. Toate contribuie la încrederea reciprocă și la calitatea actului medical, chiar în absența proximității fizice.

Responsabilitatea comună

Telemedicina amplifică rolul comunicării în protejarea demnității pacientului. Respectul, discreția și claritatea devin forme de protecție morală la fel de importante ca securitatea digitală. Într-un spațiu unde tehnologia intermediază contactul uman, etica se traduce prin grijă — pentru date, pentru cuvânt și pentru persoana din fața ecranului.

9.7 Direcții emergente

Telemedicina evoluează rapid dincolo de simpla consultație la distanță, devenind o parte a unei rețele clinice distribuite, în care datele, algoritmi și oamenii colaborează în timp real. Ceea ce până recent părea experiment — monitorizarea continuă, chirurgia asistată de la distanță, analiza automată a imaginilor — devine tot mai des rutină medicală.

Telemedicina asistată de inteligență artificială

Integrarea **inteligenței artificiale (AI)** în platformele de telemedicină transformă modul în care medicii procesează informațiile. Algoritmi pot analiza în câteva secunde mii de imagini, valori fiziologice sau modele de comportament, semnalând deviațiile semnificative și prioritizând cazurile urgente. În telemonitorizarea pacienților cronici, sistemele AI învață tiparul individual al fiecărui pacient și pot anticipa o decompensare cardiacă sau o hipoglicemie cu ore înainte de apariția simptomelor.

Totuși, rolul AI rămâne acela de **instrument de suport decizional**, nu de substitut al medicului. Responsabilitatea clinică și validarea finală a deciziilor aparțin în continuare profesionistului, care trebuie să înțeleagă limitele algoritmului și să mențină controlul asupra procesului.

Realitatea augmentată și robotica medicală

Un alt domeniu emergent este cel al **realității augmentate (AR)** și **realității virtuale (VR)**, utilizate în teleasistență chirurgicală, reabilitare și formare medicală. Prin suprapunerea imaginilor 3D peste câmpul vizual real, AR

permite medicului expert să ghideze echipa locală ca și cum ar fi prezent în sala de operație.

În **telechirurgia robotică**, combinația dintre imagistică de înaltă rezoluție, conexiuni 5G și interfețe haptice face posibilă transmiterea precisă a gesturilor operatorii la mii de kilometri distanță. Deși aplicarea clinică rămâne limitată la centre specializate, aceste tehnologii deschid calea către un nou model de colaborare medicală — în care expertiza circulă mai rapid decât pacientul.

În reabilitare, realitatea virtuală permite antrenarea mișcărilor într-un mediu controlat, sub supravegherea terapeutului conectat online, transformând telemedicina într-un proces activ, interactiv și motivant.



Figura 9.3. Robotul Da Vinci – foto autor necunoscut, sub licență [CC BY-SA-NC](#)

Spațiul European al Datelor privind Sănătatea (EHDS)

La nivel european, telemedicina va fi integrată într-un cadru digital unitar prin **Spațiul European al Datelor privind Sănătatea (European Health Data Space – EHDS)**. Acest proiect urmărește ca orice cetățean să poată accesa și partaja în siguranță propriile date medicale, indiferent de țară sau furnizor de servicii.

Pentru România, aceasta înseamnă conectarea treptată a sistemelor naționale la rețeaua **eHDSI**, care asigură schimbul standardizat al fișelor electronice,

prescripțiilor și rapoartelor medicale între statele membre. Teleconsultațiile transfrontaliere, realizate între medici din diferite țări, vor deveni astfel nu doar posibile, ci și reglementate, cu garanții comune privind confidențialitatea și interoperabilitatea.

EHDS va reprezenta infrastructura de bază pentru medicina distribuită a viitorului, unde datele pacientului pot fi analizate de echipe multidisciplinare, susținute de AI, fără a mai fi nevoie de deplasarea fizică. Telemedicina devine, astfel, **nucleul practic al sănătății digitale europene**.

De la telemedicină la medicina distribuită

Direcția actuală merge spre o **medicină distribuită**, în care distanța nu mai delimitează competența, iar informația circulă liber, dar controlat. Consultația, monitorizarea, decizia terapeutică și evaluarea rezultatelor se desfășoară în rețea, într-un continuum digital ce unește pacientul, medicul, instituția și sistemul de sănătate.

În acest context, telemedicina nu mai este o excepție, ci o nouă normalitate – expresia maturității digitale a medicinei moderne, unde tehnologia amplifică, fără a substitui, relația umană și responsabilitatea profesională.

Telemedicina reprezintă punctul de convergență dintre tehnologie și profesia medicală. Ea transformă informația din simplu suport decizional în instrument direct al actului clinic, făcând posibilă îngrijirea la distanță fără a rupe legătura umană dintre medic și pacient.

Prin arhitectura sa tehnică, prin standardele de interoperabilitate și prin reglementarea juridică actuală, telemedicina devine parte integrantă a sistemului de sănătate românesc și european. Noile direcții — inteligența artificială, realitatea augmentată, medicina distribuită — nu îi schimbă esența, ci îi extind potențialul.

Pentru viitorii medici, înțelegerea telemedicinei nu înseamnă doar familiaritate cu instrumentele digitale, ci mai ales conștientizarea modului în care responsabilitatea, empatia și discernământul profesional se traduc într-un mediu virtual.

De reținut

- Telemedicina este forma digitală a actului medical, desfășurat la distanță, cu valoare juridică echivalentă consultației clasice.
- Principalele servicii includ: teleconsultația și teleexpertiza și telemonitorizarea.
- Securitatea și confidențialitatea datelor sunt esențiale
- Comunicarea digitală cere dezvoltarea unui *webside manner* empatic și profesionist.
- Direcțiile emergente includ integrarea inteligenței artificiale, a realității augmentate și a Spațiului European al Datelor de Sănătate.

Capitolul 10 – Decizia medicală asistată și aplicații ale inteligenței artificiale în medicină

10.1. Rolul deciziei medicale asistate

Decizia medicală asistată reprezintă un domeniu central al informaticii medicale moderne, situat la intersecția dintre cunoașterea clinică și analiza algoritmică. Ea reunește toate acele procese prin care sistemele informatice sprijină medicul în stabilirea diagnosticului, alegerea investigațiilor, optimizarea tratamentului și coordonarea activităților manageriale dintr-un serviciu medical. Nu este vorba despre o înlocuire a raționamentului uman, ci despre o extindere a lui, prin capacitatea calculatorului de a integra volume mari de date și de a aplica reguli logice sau modele statistice într-un timp foarte scurt.

În acest context s-au dezvoltat **sistemele informatice de suport al deciziei clinice** (Clinical Decision Support Systems – CDSS), concepute pentru a furniza „informația potrivită, persoanei potrivite, în formatul potrivit, prin canalul potrivit și la momentul potrivit” – principiul celor „Five Rights” formulat de Osheroff (2009). Aceste sisteme pot fi accesate la cerere sau pot funcționa automat, fie integrate în dosarul electronic al pacientului, fie ca aplicații independente. Ele se adresează nu doar medicilor, ci și altor profesioniști din domeniul sănătății – asistenți, tehnicieni sau personal administrativ – oferind alerte, mesaje, îndrumări sau recomandări pentru alegerea celei mai potrivite investigații sau terapii.

O direcție tot mai importantă a acestor sisteme o constituie **managementul proceselor clinice**. Implementarea unui CDSS începe prin formalizarea protocoalelor diagnostice sau terapeutice, în care sunt definite activitățile specifice unui plan de îngrijire, relațiile dintre ele, nodurile de decizie și parametrii de calitate, siguranță și eficiență. Această structurare face posibilă urmărirea în timp real a parcursului pacientului: cunoscând starea sa actuală și indicatorii corespunzători, sistemul poate genera alerte automate care să ghideze medicul către decizia optimă.

Responsabilitatea actului medical rămâne întotdeauna a medicului, dar deciziile și căile de execuție parcurse sunt ulterior analizate pentru a îmbunătăți performanța algoritmilor. În acest fel, sistemul de suport devine un

instrument adaptiv, capabil să învețe din practica medicală și să crească în timp eficiența și calitatea îngrijirii.

Principiile deciziei asistate au fost extinse și către pacient, prin aplicații interactive care îi permit să își evalueze simptomele și să obțină sugestii preliminare privind posibile cauze sau direcții de investigație. Aceste platforme – cunoscute sub denumirea de *symptom checkers* – folosesc aceleași mecanisme logice și statistice ca sistemele clinice, dar într-o formă simplificată și orientată spre educație și auto-îngrijire.

The screenshot shows the 'Symptom Checker: Symptoms & Signs A-Z' interface. At the top, it says 'Name: Me', 'Gender: Male', and 'Age: 45-54 years'. There are links for 'Start Over', 'Print', and 'Take the Tour'. The interface is divided into three main sections:

- 1 Choose Symptom(s)**: This section includes a 'Body Map' on the left and a 'Search:' field on the right. Below the search field is a list of symptoms to select, such as 'Pain or discomfort (Forearm (flexor))', 'Pain or discomfort (Forearm)', 'Pain or discomfort (Genitals)', 'Pain or discomfort (Groin)', 'Pain or discomfort (Hamstring)', 'Pain or discomfort (Hand)', 'Pain or discomfort (Jaw)', 'Pain or discomfort (Lateral Chest)', 'Pain or discomfort (Lower Abdomen)', 'Pain or discomfort (Lower Spine)', and 'Pain or discomfort (Mouth)'. There are also buttons for 'Back View', 'Select Entire Abdomen', and 'Zoom Out'. A 'Don't know where to point?' section with a 'More symptoms here' link is also present.
- 2 Your Choices**: This section shows the selected symptoms, including 'Black colored skin', 'Cold hands', 'Multiple bruises of different ages', and 'Pain or discomfort'.
- 3 Possible Conditions**: This section shows a list of possible conditions, including 'Restless legs syndrome', 'Lumbar (low back) herniated disk', 'Peripheral neuropathy', 'Sciatica', 'Aortic aneurysm (abdomen)', and 'Giant cell arteritis (temporal)'. There is also a 'Thanks for the feedback!' message with a 'Back' link and a 'Help us show you better ads by updating your ads settings' link.

Figura 10.1. Interfață de tip „symptom checker”, utilizată pentru auto-evaluarea stării de sănătate. Platforma ghidează utilizatorul prin selectarea simptomelor, generând o listă de posibile diagnostice. Astfel de aplicații traduc logica sistemelor de decizie clinică în instrumente educaționale destinate pacienților, sprijinind conștientizarea și orientarea timpurie către serviciile medicale.

Astfel, decizia asistată de calculator se bazează pe trei fundamente metodologice care vor fi dezvoltate în secțiunile următoare: **metodele logice**, care utilizează reguli și arbori de decizie; **metodele statistice**, bazate pe probabilități și modele bayesiene; și **metodele euristice**, specifice sistemelor expert. Împreună, ele definesc mecanismele prin care cunoașterea medicală poate fi formalizată, aplicată și perfecționată cu ajutorul inteligenței artificiale.

10.2. Metode logice de decizie asistată

Primele sisteme de decizie medicală au fost construite pe baze logice, folosind reprezentări simple de tip binar – *adevărat* sau *fals*, *da* sau *nu*. În această viziune, diagnosticul rezultă dintr-un lanț de reguli logice, prin care prezența sau absența anumitor simptome activează sau exclude o boală. Modelul logic, deși aparent rigid, a permis primele încercări de formalizare a raționamentului medical, transformând procesul intuitiv al clinicianului într-o succesiune clară de întrebări și decizii.

La baza acestor metode se află conceptul de **bază de cunoștințe** (BC), organizată sub forma unei matrici care corelează bolile (B) cu simptomele (S). Fiecărei combinații i se atribuie o valoare binară: 1 dacă simptomul este prezent în boală, 0 dacă lipsește. În paralel, pentru fiecare pacient se construiește un **vector de stare** (VSP), care descrie simptomele observate. Procesul de diagnostic constă în compararea acestui vector cu liniile bazei de cunoștințe și calcularea unui scor de similitudine. Boala cu cel mai mare scor devine ipoteza diagnostică probabilă.

Symptoms	Cervical Cancer	Ovarian Cancer	Uterine Cancer	Vaginal Cancer	Vulvar Cancer
Abnormal vaginal discharge	●	●	●	●	
Pelvic pain or pressure		●	●		●
Abdominal or back pain		●			
Bloating		●			
Changes in bathroom habits		●		●	
Itching or burning of the vulva					●
Changes in vulva color or skin, such as a rash, sores, or warts					●
Abnormal vaginal bleeding	●	●	●	●	

Un exemplu simplu este oferit de aplicațiile de tip *symptom checker* (precum cele ilustrate anterior), care cer utilizatorului să selecteze simptomele resimțite și, pe baza unei baze de date prestabilite, afișează o listă de posibile afecțiuni. Într-un sens mai general, același mecanism logic stă la baza sistemelor clinice de triaj, care filtrează automat pacienții după urgență sau tipul de simptomatologie.

O altă formă de reprezentare logică o constituie **arborii de decizie**. Aceștia sunt structuri ierarhice care ghidează raționamentul pas cu pas, pornind de la o întrebare generală și ajungând la concluzii specifice. Fiecare nod al arborelui reprezintă o întrebare, iar fiecare ramură corespunde unui răspuns posibil (de regulă „da” sau „nu”). Prin parcurgerea arborelui, sistemul poate evita întrebările inutile, adaptând interogatoriul la răspunsurile pacientului și reducând astfel volumul de date necesar.

Un exemplu clasic îl reprezintă transformarea ghidurilor clinice în algoritmi decizionali. În cazul hipertensiunii arteriale, de pildă, protocolul medical poate fi transpus într-un arbore de decizie care începe cu măsurarea tensiunii arteriale, urmată de ramificații succesive: confirmarea valorilor crescute, evaluarea cauzelor secundare, modificarea stilului de viață, adăugarea terapiei medicamentoase sau trimiterea la specialist (fig. 10.2).




Figura 10.2. Transformarea unui ghid terapeutic și diagnostic pentru hipertensiunea arterială într-un algoritm decizional. Reprezentarea logică în format de arbore permite automatizarea procesului decizional și integrarea sa în sistemele informatice de suport clinic (CDSS).

Metodele logice prezintă numeroase avantaje: sunt transparente, ușor de urmărit și ușor de explicat. Ele redau fidel modul în care medicul gândește secvențial, formulând ipoteze și testându-le în funcție de simptome. În același timp, aceste metode au și limitări importante. Ele nu pot exprima gradul de intensitate al simptomelor și nu țin cont de importanța relativă a acestora. În plus, nu reflectă prevalența bolilor în populație, tratând toate ipotezele ca fiind la fel de probabile.

Cu toate acestea, logica binară a rămas un punct de plecare indispensabil pentru sistemele moderne de decizie asistată. Ea a furnizat structura de bază pentru dezvoltarea metodelor statistice și a celor euristice, care vor adăuga ulterior nuanțe de probabilitate, învățare și adaptare continuă.

10.3. Metode statistice și de recunoaștere a tiparelor

Pe măsură ce medicina a început să acumuleze volume uriașe de date, abordarea strict logică s-a dovedit insuficientă. Diagnosticul nu depinde doar de prezența sau absența unor simptome, ci și de frecvența lor în populație, de corelațiile dintre ele și de contextul clinic. Din această nevoie de nuanțare s-au născut **metodele statistice** de decizie asistată, fundamentate pe teoria probabilităților.

Cea mai cunoscută dintre acestea este **regula lui Bayes**, care descrie modul în care se actualizează probabilitatea unei ipoteze în funcție de datele noi observate. În termeni simpli, ea exprimă raționamentul medical de tipul: *„având în vedere acest simptom, cât de probabil este ca pacientul să aibă boala B?”*

Formula generală este:

$$P(B|S) = \frac{P(S|B) \times P(B)}{P(S)} \quad (10.1)$$

unde:

- $P(B|S)$ este **probabilitatea ca pacientul să aibă boala B** dacă prezintă simptomul S (probabilitate condiționată);
- $P(S|B)$ reprezintă **probabilitatea ca simptomul să fie prezent în cazul bolii B** (Se - sensibilitatea testului); $P(S|-B)$ reprezintă Sp - specificitatea
- $P(B)$ este **probabilitatea inițială** ca pacientul să aibă boala (P - prevalența bolii în populație);
- $P(S)$ este **probabilitatea totală de apariție a simptomului**, indiferent de cauză. Întrucât $P(S)$ nu se cunoaște la nivelul populației, poate fi derivat din formula $P(S) = (Se \times P) + [(1-Se) \times (1-P)]$

Această formulă permite medicului (sau sistemului informatic) să combine datele populaționale cu observațiile clinice pentru a ajunge la o estimare numerică a riscului individual.

În cadrul unui sistem de decizie asistată bazat pe regula lui Bayes, pentru fiecare pereche *boală-simptom*, sistemul poate calcula o valoare $P(B | S)$, iar totalitatea acestor valori constituie **baza de cunoștințe probabilistice** a sistemului. În practică, o astfel de bază permite evaluarea automată a pacienților: fiecare simptom observat contribuie la actualizarea probabilităților pentru toate bolile posibile.

Atunci când există mai multe simptome, adică *evenimente compuse*, se aplică regula **sumei probabilităților** pentru situațiile de tip *sau* (simptome alternative) și regula **produsului probabilităților** pentru situațiile de tip *și* (simptome simultane). În aceste cazuri, este esențial să se verifice independența variabilelor, de exemplu prin testul χ^2 .

Exemplu clinic:

Să presupunem că într-o populație de adulți, prevalența tuberculozei pulmonare este de 1%. O radiografie toracică are o **sensibilitate** de 90% (adică depistează corect 90% dintre cazurile reale) și o **specificitate** de 95% (adică este fals pozitivă la 5% dintre persoanele sănătoase).

Pentru un pacient care are radiografia pozitivă, probabilitatea ca el să aibă efectiv tuberculoză nu este de 90%, cum s-ar putea crede intuitiv, ci mult mai mică. Aplicând regula lui Bayes:

$$P(B|S) = (0.90 \times 0.01) / (0.90 \times 0.01 + 0.05 \times 0.99) = 0.15$$

Rezultă că, deși testul este foarte performant, **doar 15% dintre cei cu rezultat pozitiv au cu adevărat boala**, din cauza prevalenței scăzute. Invers, în populațiile cu prevalență mare, aceeași valoare a testului ar fi mult mai sugestivă.

Acesta este raționamentul bayesian aplicat în medicină: fiecare simptom sau test modifică probabilitatea inițială a bolii, iar diagnosticul final rezultă din cumulul acestor actualizări succesive.

Regula lui Bayes nu se aplică doar testelor de laborator, ci și analizei semnelor clinice, a rezultatelor imagistice sau a scorurilor de risc. Ea stă la baza sistemelor de decizie probabilistică, care nu oferă răspunsuri de tip „da/nu”, ci **grade de încredere** exprimate prin procente.

Un exemplu familiar este **calculatorul de risc cardiovascular ESC SCORE2**, care estimează probabilitatea unui eveniment major (infarct, AVC) pe baza vârstei, sexului, tensiunii arteriale, colesterolului și statutului de fumător (fig. 10.3). Deși medicul nu vede direct formulele bayesiene, logica internă este aceeași: fiecare parametru adaugă sau reduce o parte din probabilitatea finală.




Figura 10.3. Exemple de aplicare a metodelor statistice în predicția riscului cardiovascular.

Hărțile SCORE și calculatoarele integrate de risc oferă estimări probabilistice ale evenimentelor majore, facilitând deciziile personalizate privind prevenția și tratamentul.

Metodele statistice de acest tip au fost ulterior extinse în domeniul **recunoașterii tiparelor** (*pattern recognition*), care caută asemănări între pacienți pe baza unor combinații complexe de variabile. Fiecare pacient poate fi descris printr-un set de atribute – biologice, clinice sau imagistice – reprezentate într-un spațiu multidimensional. În acest spațiu, pacienții cu trăsături similare formează *cluster*e corespunzătoare unor boli sau sindroame.

Astfel, analiza statistică și recunoașterea tiparelor oferă medicului o perspectivă probabilistică, realistă și personalizată asupra diagnosticului. Ele constituie fundamentul pentru metodele moderne de învățare automată, unde algoritmi încep să descopere singuri regularitățile ascunse din datele clinice, continuând drumul deschis de logica bayesiană.

10.4. Metode euristice – sistemele expert

Dacă metodele logice urmăresc precizia formală, iar cele statistice operează cu probabilități, **metodele euristice** încearcă să reproducă raționamentul uman, cu tot ce presupune acesta: experiență, intuiție și adaptare la situații neprevăzute. Ele au apărut în anii '70–'80, odată cu primele încercări de a transpune în limbaj informatic cunoștințele unui specialist, sub forma unor reguli, concepte și relații.

Un **sistem expert** este o aplicație capabilă să imite procesul decizional al unui expert uman într-un domeniu bine definit. În medicină, aceste sisteme au fost folosite pentru diagnostic, alegerea tratamentului, interpretarea analizelor de laborator sau planificarea procedurilor terapeutice.

La nivel structural, un sistem expert include cinci componente principale:

- **Sistemul cognitiv**, care conține baza de cunoștințe, structurată pe trei niveluri: factual (date brute, rezultate, simptome), conceptual (noțiuni clinice și relații între concepte) și metacognitiv (reguli despre modul de utilizare a cunoștințelor).
- **Sistemul rezolutiv** sau motorul de inferență, care preia datele introduse de utilizator, selectează regulile relevante și derivă concluziile posibile. Acesta reprezintă „motorul de raționament” al sistemului.
- **Sistemul explicativ**, care are rolul de a justifica deciziile propuse – un aspect esențial în context medical, unde orice recomandare trebuie să poată fi urmărită și înțeleasă.
- **Sistemul de comunicare**, adică interfața cu utilizatorul, care permite introducerea datelor și afișarea rezultatelor într-o formă intuitivă, apropiată de limbajul natural.
- **Sistemul metarezolutiv**, responsabil de evaluarea performanței și de ajustarea algoritmilor în funcție de feedbackul utilizatorilor.

Procesul decizional într-un sistem expert începe prin **interogarea pacientului sau a bazei de date clinice**, după care motorul de inferență activează regulile potrivite (fig. 10.4). Pe baza răspunsurilor obținute, sistemul generează o listă de diagnostice posibile, fiecare însoțit de o explicație: „acest diagnostic este sugerat deoarece simptomele X și Y sunt prezente, iar testul Z are rezultat pozitiv.” Această transparență face ca sistemele expert să fie nu doar

instrumente decizionale, ci și mijloace educaționale utile pentru formarea medicilor.




Figura 10.4. Structura generală a unui sistem expert medical cu fluxurile de date:

- 1) U → S.COM. → S.REZ.; 2) S.REZ. ↔ S.COĞ.; 3) S.COĞ. ↔ B.CUN.;
- 4) S.REZ. → S.EXP.; 5) S.EXP. → S.COM.; 6) S.COM. → U; 7) S.REZ. ↔ S.MET.;

Primele aplicații de succes au fost **MYCIN**, dezvoltat la Universitatea Stanford pentru diagnosticul infecțiilor bacteriene, și **INTERNIST-1**, destinat medicinei interne generale, capabil să gestioneze sute de boli pe baza unor mii de reguli logice și euristice. Deși aceste sisteme funcționau pe calculatoare modeste, principiile lor rămân actuale: extragerea cunoștințelor de la experți, formalizarea lor în reguli „dacă-atunci” și actualizarea continuă în funcție de experiența clinică acumulată.

Un exemplu mai recent îl constituie sistemele expert educaționale integrate în platformele de e-learning, care pot explica raționamente clinice pas cu pas, imitând dialogul dintre profesor și student. În mediul spitalicesc, unele module de decizie asistată folosesc același principiu euristic pentru a semnaliza posibile interacțiuni medicamentoase sau contraindicații pe baza istoricului pacientului.

Metodele euristice aduc astfel medicina digitală mai aproape de gândirea umană, reușind să îmbine structura logică a algoritmilor cu flexibilitatea experienței clinice. Ele reprezintă puntea de legătură între sistemele expert clasice și **inteligenta artificială (AI)** contemporană, care extinde aceste mecanisme prin învățare automată și rețele neuronale.

10.5. Calitatea deciziei și validarea sistemelor

Calitatea unui sistem de suport decizional nu se rezumă la performanța tehnică, ci la măsura în care el discriminează corect între pacienții bolnavi și cei sănătoși, oferind rezultate consecvente și utile clinic. Evaluarea acestor sisteme implică un set de indicatori cantitativi, dar și o validare continuă a relevanței lor în practica reală.

Indicatori de performanță

Analiza începe cu **matricea de confuzie**, care compară predicțiile algoritmului cu realitatea clinică. Aceasta cuprinde:

- **Real pozitivi (RP)** – pacienți bolnavi identificați corect;
- **Real negativi (RN)** – persoane sănătoase clasificate corect;
- **Fals pozitivi (FP)** – persoane sănătoase etichetate greșit ca bolnave;
- **Fals negativi (FN)** – pacienți bolnavi pe care sistemul nu i-a recunoscut.

		Clasificator	
		B+	B-
Real	B+	RP	FN
	B-	FP	RN

Pe baza acestor valori se calculează principalii indicatori de performanță:

$$\text{Sensibilitate (Se)} = \text{RP} / (\text{RP} + \text{FN}) . \quad (10.2)$$

Reprezintă proporția cazurilor reale pozitive identificate corect. Un sistem cu sensibilitate mare „vede” aproape toate cazurile.

$$\text{Specificitate (Sp)} = \text{RN} / (\text{RN} + \text{FP}) \quad (10.3)$$

Exprimă proporția cazurilor reale negative identificate corect. Un sistem foarte specific greșește rar, dar poate rata cazurile subtile.

$$\text{Valoare predictivă pozitivă (VPP)} = \text{RP} / (\text{RP} + \text{FP}) \quad (10.4)$$

Indică probabilitatea ca un rezultat pozitiv să corespundă unui pacient bolnav.

$$\text{Valoare predictivă negativă (VPN)} = \text{RN} / (\text{RN} + \text{FN}) \quad (10.5)$$

Reprezintă probabilitatea ca un rezultat negativ să excludă corect boala.

$$\text{Acuratețe (Ac)} = (\text{RP} + \text{RN}) / (\text{RP} + \text{RN} + \text{FP} + \text{FN}) \quad (10.6)$$

Măsoară proporția totală a clasificărilor corecte, dar poate fi înșelătoare când boala are prevalență scăzută.

$$\text{Rata erorii (RE)} = (\text{FP} + \text{FN}) / (\text{RP} + \text{RN} + \text{FP} + \text{FN}) \quad (10.7)$$

Arată proporția totală a cazurilor clasificate greșit.


Indicatorii trebuie interpretați împreună: sensibilitatea ridicată crește detecția, dar scade specificitatea; un echilibru între ele depinde de scopul clinic al sistemului – screening, diagnostic diferențial sau monitorizare.

Curba ROC și aria de sub curbă (AUC)

Când algoritmul generează un scor de probabilitate, performanța sa se exprimă prin **curba ROC (Receiver Operating Characteristic)**. Aceasta descrie variația **sensibilității** în funcție de **1 – specificitate**, pentru toate pragurile posibile ale deciziei.

O curba ROC ideală atinge colțul stânga-sus al graficului ($Se = 1$, $Sp = 1$), în timp ce o clasificare aleatorie produce o linie diagonală ($AUC = 0,5$). **Aria de sub curbă (AUC)** sintetizează performanța globală:

- a) $AUC\ 0,8-0,9$ – foarte bună;
- b) $AUC\ 0,7-0,8$ – moderată;
- c) $AUC \approx 1,0$ – performanță excelentă;
- d) $AUC < 0,7$ – slabă.



Pragul optim de decizie se poate determina prin **indicele Youden**:

$$J = Se + Sp - 1 \quad (10.8)$$

care maximizează diferența dintre detecțiile corecte și erorile comise.

Rapoarte de verosimilitate (Likelihood Ratios)

În practica clinică, **rapoartele de verosimilitate (LR)** oferă o legătură directă între rezultatul testului și probabilitatea post-test a bolii.

$$LR^+ = Se / (1 - Sp) \quad (10.9)$$

$$LR^- = (1 - Se) / Sp \quad (10.10)$$

Un **LR^+** mare (>10) crește puternic probabilitatea diagnosticului, în timp ce un **LR^-** mic ($<0,1$) o reduce semnificativ. Aceste valori pot fi folosite în formule bayesiene sau pe nomograme pentru a converti probabilitatea pre-test (intuitivă) într-una post-test (cuantificată).

Pentru claritate didactică, formulele 10.1-10.10 nu trebuie memorate, ci înțelese conceptual.

Calibrarea și beneficiul clinic

Performanța matematică nu garantează utilitate clinică. Un model bine calibrat prezice riscul într-o manieră proporțională cu realitatea – dacă estimează 20%, aproximativ 1 din 5 cazuri similare se confirmă. Calibrarea se verifică grafic (diagrame prevăzut–observat) sau numeric (interceptă și pantă de calibrare, scorul Brier).

Pe lângă discriminare și calibrare, se evaluează **beneficiul net clinic** – balanța dintre adevăratele detecții și costul alarmei false. Analiza de tip **decision curve** compară strategia modelului cu alternativele „tratează pe toți” sau „pe nimeni”, identificând dacă sistemul aduce valoare adăugată reală.

Validarea internă și externă

Un model trebuie validat pe mai multe niveluri:

- **validare internă**, prin împărțirea eșantionului (k-fold cross-validation, bootstrap), pentru a testa stabilitatea internă;
- **validare externă**, pe populații și contexte diferite, singura care confirmă generalizarea și robustețea sistemului.

După implementare, modelele trebuie monitorizate în timp: modificarea prevalenței, introducerea unor noi ghiduri sau schimbarea tehnologiilor pot duce la „*model drift*” – scăderea performanței fără ca algoritmul să fie modificat. Recalibrarea periodică, auditul alertelor și controlul oboselii la alarmă (*alert fatigue*) sunt măsuri esențiale pentru menținerea încrederii în sistem.

În plus, evaluarea etică și analiza **bias-ului** (diferențe de performanță între sexe, grupe de vârstă sau regiuni) fac parte din procesul de certificare și reglementare, mai ales în sistemele AI de uz clinic.

Exemplu numeric

Pentru a ilustra modul de evaluare a performanței unui sistem decizional, să considerăm un sistem de diagnostic automat pentru depistarea pneumoniei pe baza imaginilor radiografice toracice. Sistemul a fost testat pe un lot de 1000

de pacienți internați în secția de urgență, dintre care 200 aveau pneumonia confirmată ulterior prin investigații de laborator și examen clinic complet.

Modelul a clasificat fiecare radiografie drept pozitivă (prezența pneumoniei) sau negativă (absența acesteia), rezultând următoarea distribuție:

	Pneumonie prezentă	Pneumonie absentă	Total
Test pozitiv	180	80	260
Test negativ	20	720	740
Total	200	800	1000

Rezultatele pot fi interpretate astfel:

- dintre cei 200 de pacienți bolnavi, **180 au fost identificați corect** (real pozitivi), iar **20 au fost omiși** (fals negativi);
- dintre cei 800 de pacienți sănătoși, **720 au fost clasificați corect** (real negativi), iar **80 au fost evaluați greșit** ca pozitivi (fals pozitivi).

Pe baza acestor date se calculează indicatorii principali:

$$Se = 180 / (180 + 20) = 0.90; Sp = 720 / (720 + 80) = 0.90$$

$$VPP = 180 / (180 + 80) = 0.69; VPN = 720 / (720 + 20) = 0.97$$

$$Ac = (180 + 720) / 1000 = 0.90; RE = 1 - 0.90 = 0.10$$

$$LR^+ = 0.90 / (1 - 0.90) = 9; LR^- = (1 - 0.90) / 0.90 = 0.11$$

Interpretare: testul are o **discriminare excelentă** ($AUC \approx 0,9$) și un **$LR^+ = 9$** , ceea ce înseamnă că un rezultat pozitiv crește de nouă ori probabilitatea bolii. În schimb, un rezultat negativ ($LR^- = 0,11$) reduce probabilitatea la aproape o zecime din cea inițială – performanță adecvată pentru un test de diagnostic.

Astfel, calitatea unui sistem decizional derivă nu doar din precizia algoritmică, ci și din capacitatea de a oferi rezultate stabile, explicabile și utile clinic. Un model bun poate arăta impresionant pe curba ROC, dar un sistem cu adevărat valoros este acela care **schimbă în bine deciziile medicale**, sprijinind medicul fără a-i diminua autonomia profesională.

10.6. Machine Learning- învățarea automată

Evoluția sistemelor informatice medicale a fost marcată de trecerea de la modele bazate pe reguli fixe, construite manual, la modele capabile să învețe din date. În loc ca un programator sau un medic să formuleze explicit regulile diagnostice, **machine learning** (ML) permite ca acestea să fie deduse direct din observațiile clinice. Această schimbare de paradigmă a mutat accentul de pe cunoașterea declarativă pe cea inductivă — extragerea de tipare din experiența acumulată.

În medicină, ML este utilizată pentru a descoperi relații subtile între simptome, rezultate de laborator, imagini sau date genetice, care pot scăpa raționamentului uman. Prin analizarea simultană a mii de variabile, algoritmi pot identifica regularități invizibile, construind modele care, odată antrenate, pot anticipa diagnosticul, riscul sau evoluția unei boli.

Învățarea automată nu este un concept unitar, ci o familie de metode care diferă prin modul de raportare la date. În forma **supervizată**, algoritmul pornește de la cazuri cunoscute — fiecare exemplu are o etichetă corectă, precum „tumoră benignă” sau „malignă”. Sistemul învață din aceste exemple să recunoască tiparele care separă cele două clase, urmând ca ulterior să aplice regula descoperită asupra cazurilor noi. În forma **nesupervizată**, datele nu au etichete, iar scopul este identificarea automată a grupărilor naturale — de exemplu, subtipuri de pacienți cu același diagnostic aparent, dar cu evoluții diferite. O variantă intermediară, **semi-supervizată**, combină un mic număr de cazuri etichetate cu un volum mare de date neetichetate, iar învățarea **prin întărire** presupune explorarea unui mediu și ajustarea deciziilor pe baza recompenselor primite, model inspirat din comportamentul adaptativ.

Procesul de învățare urmează de obicei aceeași logică, indiferent de algoritm. Datele sunt mai întâi colectate și curățate — se elimină erorile, valorile lipsă și se normalizează scările. Urmează etapa de antrenare, în care sistemul descoperă relațiile dintre variabile. Apoi, modelul este testat pe un set de cazuri noi pentru a evalua cât de bine generalizează regulile învățate. Modelele performante sunt ulterior optimizate și integrate în fluxul clinic, unde pot furniza scoruri de risc, sugestii de diagnostic sau alerte automate.




Figura 10.5. Procesul de învățare automată: inducția modelului din datele de antrenare și deducția rezultatelor pe datele de testare.

În funcție de natura datelor, se pot aplica diverse clase de algoritmi, fiecare având puncte forte și limite:

- **Arbori de decizie și păduri aleatorii (Random Forests)** – modele intuitive, ușor de explicat, utilizate pentru clasificarea pacienților după risc.
- **Regresie logistică și regresie multinomială** – foarte folosite în epidemiologie și predicția evenimentelor binare (de exemplu, supraviețuire la 30 de zile).
- **Naïve Bayes** – algoritm probabilistic bazat pe independența variabilelor; aplicabil în clasificarea textelor medicale sau analiza raportărilor de simptome.
- **Metode bazate pe distanță (k-Nearest Neighbors)** – utile în identificarea cazurilor similare, în special în diagnostic diferențial.
- **Rețele neuronale (NN)** – modele inspirate de creierul biologic, capabile să identifice tipare complexe în imagini, semnale sau texte.

 *Exemple clinice* sunt numeroase. În radiologie, sistemele de învățare automată pot detecta leziuni pulmonare sau hemoragii intra-craniene cu o precizie comparabilă cu cea a specialiștilor. În cardiologie, modelele antrenate pe milioane de electrocardiograme reușesc să identifice aritmii rare în câteva

secunde. În sănătatea publică, predicțiile bazate pe ML pot anticipa complicațiile severe la pacienții cronici sau pot estima apariția unui focar epidemic pornind de la datele de laborator și mobilitatea populației.

Evaluarea acestor modele folosește aceiași indicatori descriși anterior — sensibilitate, specificitate, AUC — dar include și teste suplimentare pentru a evita supraînvățarea (*overfitting*). Datele se împart în seturi de antrenare și testare, uneori repetate în mai multe iterații (validare încrucișată). Modelele care generalizează corect sunt apoi analizate pentru **explicabilitate**, adică pentru a arăta de ce un anumit caz a fost clasificat într-un anumit mod. În aplicațiile clinice, această transparență este esențială: medicul trebuie să înțeleagă logica deciziei algoritmului, nu doar rezultatul numeric.

Astfel, învățarea automată nu înlocuiește raționamentul medicului, ci îl completează. Ea transformă datele brute în cunoaștere aplicabilă, oferind o a doua opinie consistentă și lipsită de oboseală. Rolul clinicianului rămâne acela de a valida rezultatele, de a interpreta contextul și de a păstra controlul asupra deciziei finale. Machine Learning nu este un substitut al gândirii medicale, ci un partener de învățare care amplifică precizia și viteza cu care aceasta poate acționa.


10.7. Dimensiunile operaționale ale inteligenței artificiale

Inteligența artificială nu este o tehnologie unică, ci o familie de metode care abordează diferit problema învățării, reprezentării cunoștințelor și luării deciziilor. În funcție de modul în care este definită sarcina și de tipul de date pe care le prelucrează, AI își manifestă competențele prin câteva dimensiuni principale – de la analiza numerică și simbolică până la înțelegerea limbajului și a imaginilor. În medicină, aceste dimensiuni se completează reciproc, alcătuind un ecosistem care poate observa, interpreta și anticipa starea de sănătate.

O primă dimensiune este cea a **învățării automate (Machine Learning)**, descrisă anterior, care constituie fundamentul majorității aplicațiilor moderne. ML oferă modele capabile să identifice tipare și să prezică evoluții pornind din date. Ea formează „stratul cognitiv” al inteligenței artificiale — acolo unde raționamentul este tradus în calcule și probabilități.

Cea de-a doua dimensiune este reprezentată de **rețelele neuronale artificiale (Artificial Neural Networks – ANN)**.

Acestea simulează comportamentul neuronilor biologici prin noduri interconectate, fiecare dintre ele procesând semnale și ajustând conexiunile în funcție de greșelile observate.



Rețelele neuronale profunde (*deep learning*)

pot conține zeci de straturi, ceea ce le permite să învețe reprezentări complexe – de exemplu, structura unui organ în imagini CT sau relațiile subtile dintre valorile biologice. În diagnostic, aceste rețele pot recunoaște tumori, hemoragii sau fracturi pe imagini cu un nivel de acuratețe apropiat de cel uman, dar cu o viteză net superioară.

O altă dimensiune esențială o reprezintă **vederea computerizată (Computer Vision – CV)**. Aici, algoritmi sunt antrenați să analizeze imagini medicale, filme endoscopice sau secvențe video intraoperatorii, extrăgând informații relevante fără intervenția directă a unui specialist. În radiologie, dermatologie și patologie digitală, CV a devenit o unealtă de rutină pentru detecția automată a leziunilor sau cuantificarea precisă a volumelor tumorale.

Prelucrarea limbajului natural (Natural Language Processing – NLP)

oferă o altă dimensiune a inteligenței artificiale, orientată către comunicare și înțelegerea informațiilor textuale. În sistemele informatice medicale, NLP permite interpretarea automată a scrisorilor medicale, generarea de rapoarte, extragerea datelor din note clinice sau chiar analiza conversațiilor medic-pacient. Modelele moderne de limbaj pot recunoaște intenția și tonul mesajelor, pot traduce terminologia medicală și pot furniza explicații adaptate nivelului de înțelegere al pacientului.

Complementar acestor componente, **data mining-ul** (extracția de cunoștințe din date) are rolul de a descoperi modele ascunse în volume mari de informații clinice. Prin combinarea metodelor statistice cu cele de învățare automată, data mining-ul oferă perspective asupra factorilor de risc, reacțiilor adverse, corelațiilor medicamentoase sau asocierilor genetice neașteptate. El este adesea prima etapă în construcția unui model AI, atunci când nu există ipoteze prestabilite.

Împreună, aceste dimensiuni alcătuiesc arhitectura funcțională a inteligenței artificiale medicale. Machine Learning furnizează mecanismul de raționament, rețelele neuronale adaugă profunzime și capacitatea de generalizare, vederea computerizată transformă datele vizuale în cunoaștere, NLP dă voce și sens limbajului clinic, iar data mining-ul leagă între ele toate aceste surse, generând context și predicție.

Inteligența artificială modernă nu mai este doar un algoritm, ci o rețea de tehnologii interdependente care extind percepția și judecata medicului. Fiecare dimensiune adresează un aspect al realității clinice — numeric, vizual, lingvistic sau probabilistic — iar împreună construiesc premisele unei medicini augmentate, în care decizia este împărțită între om și sistem, fără a diminua rolul niciunuia.

10.8. Inteligența artificială generativă

După decenii în care sistemele de inteligență artificială au fost construite pentru a analiza și clasifica, o nouă categorie de modele a început să „creeze”. **Inteligența artificială generativă (GenAI)** reprezintă trecerea de la algoritmi care identifică tipare la algoritmi care pot produce conținut nou — texte, imagini, sunete, cod sau simulări — bazându-se pe cunoașterea acumulată în timpul antrenării.

Modelele mari de limbaj

În centrul acestei revoluții se află **modelele mari de limbaj (Large Language Models – LLMs)**, precum **GPT-5, Claude, Gemini, DeepSeek** sau **Mistral**, capabile să înțeleagă și să genereze text, imagini sau cod, adaptându-se la cerințele specifice ale utilizatorului.

Acronimul **GPT** provine de la *Generative Pre-trained Transformer*:

- *Generative* – modelul nu doar analizează, ci generează secvențe noi de text;
- *Pre-trained* – a fost deja antrenat pe volume masive de date lingvistice, din cărți, articole, ghiduri medicale sau conversații;
- *Transformer* – denumește arhitectura internă care folosește mecanismul de „atenție” pentru a evalua simultan relațiile dintre cuvinte într-un context extins.

Funcționarea acestor modele este, în esență, probabilistică: pentru fiecare cuvânt, modelul calculează probabilitatea celor mai plauzibile continuări. Textul este construit pas cu pas, alegând mereu următorul termen cu cea mai mare probabilitate contextuală (mecanism care permite modelului să ‘acorde atenție’ contextului anterior pentru fiecare cuvânt generat). De aceea, modelele nu „știu” în sens uman, ci **estimează** ce ar fi cel mai coerent de spus în continuare.

Modelul DeepSeek, dezvoltat recent în Asia, se remarcă prin capacitatea de a combina procesarea lingvistică cu raționamentul numeric și logic, reprezentând un pas spre modelele multimodale integrate.

Exemplu clinic de utilizare Un exemplu concret este generarea automată a **rezumatului unei consultații**. Un medic introduce observațiile sale libere în sistemul electronic (anamneză, diagnostic, tratament), iar modelul generează un text structurat:

„Pacienta de 56 de ani, cunoscută cu hipertensiune arterială, prezintă valori tensionale crescute în ultimele săptămâni. Tratamentul actual include inhibitor de enzimă de conversie, doza recomandată fiind menținută. Se recomandă reevaluare la 3 luni.”

Rezultatul economisește timp și uniformizează limbajul, dar rămâne sub controlul medicului, care validează forma finală.

Prompt engineering

Calitatea acestor rezultate depinde direct de **prompt engineering** – modul în care este formulată cererea către model. Un prompt bine construit conține:

1. **Claritate** – ce se dorește exact („Generează un rezumat clinic scurt, folosind termeni medicali corecți”).
2. **Context** – informații despre pacient sau scop („pentru un student, nivel introductiv”, sau „pentru o scrisoare medicală oficială”).
3. **Specificitate** – restrângerea domeniului („doar hipertensiune arterială, fără alte comorbidități”).
4. **Exemplificare** – un exemplu de rezultat dorit („vezi structura: diagnostic, tratament, recomandări”).

Exemplu de prompt clinic complet:

„Ești un asistent medical virtual. Primești notițele medicului de familie și trebuie să redactezi o scrisoare medicală formală pentru pacient, clară, în maximum 150 de cuvinte. Include diagnostic, tratament actual și recomandări.”

Prompturile pot fi adaptate prin șabloane predefinite (*prompturi preformate*) pentru diverse sarcini clinice — de la generarea de rapoarte radiologice la redactarea instrucțiunilor de externare.

Halucinațiile și rolul RAG

Deoarece LLM-urile generează text prin probabilitate, ele pot produce **halucinații** — informații inventate, dar coerente stilistic. Într-un raport medical, o astfel de eroare poate însemna adăugarea unei medicații inexistente sau atribuirea greșită a unui diagnostic. Pentru a reduce acest risc, se folosește abordarea **Retrieval-Augmented Generation (RAG)**. În loc să se bazeze exclusiv pe memoria internă, modelul caută mai întâi informații într-o bază de date validată (de exemplu, ghidurile clinice actualizate), apoi generează textul pe baza acelor surse. Practic, RAG conectează modelul la cunoaștere externă reală, transformându-l dintr-un generator liber într-un sistem de sinteză controlată.

Considerații etice și de responsabilitate

Puterea acestor instrumente ridică probleme de etică și responsabilitate. Modelele pot amplifica **bias-urile** existente în date (de exemplu, reprezentarea inegală a genului, etniei sau vârstei) și pot produce rezultate dificil de verificat. În medicină, transparența și trasabilitatea sunt obligatorii: fiecare răspuns ar trebui să permită identificarea surselor, iar decizia finală să aparțină întotdeauna medicului.

Inteligența artificială generativă nu este un înlocuitor al judecății profesionale, ci un **partener cognitiv** care completează munca umană. Folosită cu discernământ, ea poate simplifica comunicarea, poate personaliza educația medicală și poate aduce informația științifică mai aproape de pacient — transformând datele în dialog și cunoașterea în relație.

10.9. Inteligența artificială generală și tendințele viitoare

Inteligența artificială, în sens larg, desemnează ansamblul metodelor și sistemelor capabile să **simuleze procese cognitive umane** — învățare, raționament, planificare, percepție și comunicare. În forma sa clasică, AI a fost definită drept „știința construirii de mașini care pot face lucruri ce ar necesita inteligență dacă ar fi realizate de oameni” (John McCarthy, 1955).

De la raționament simbolic la rețele neuronale

Istoria domeniului urmează o succesiune de valuri. Primul, cel al **AI simbolice** (anii '50–'70), a căutat să reproducă logica umană prin reguli explicite: sisteme care manipulau simboluri și executau raționamente deductive. Următorul val, cel **conexionist**, a adus rețelele neuronale și ideea că inteligența poate fi rezultatul emergent al conexiunilor simple dintre unități elementare. Ulterior, **învățarea automată** a introdus algoritmi capabili să deducă regulile direct din date, iar în ultimul deceniu **modelele profunde (deep learning)** au transformat complet câmpul prin abilitatea de a analiza imagini, sunete și texte cu o precizie supraumană.

Astfel, inteligența artificială modernă nu mai este doar un ansamblu de reguli, ci un ecosistem de modele adaptative. În prezent, sistemele de tip *multimodal transformer* pot combina simultan limbaj, imagine, voce și date numerice, apropiindu-se de o formă incipientă de înțelegere generalizată.

Inteligența artificială generală (AGI)

Termenul **AGI – Artificial General Intelligence** descrie un sistem care ar putea învăța și raționa în contexte variate, transferând cunoștințele dobândite dintr-un domeniu în altul. În teorie, un astfel de sistem ar fi capabil să rezolve probleme nedefinite anterior, să interpreteze intențiile umane și să-și perfecționeze propriile metode de învățare. AGI nu implică conștiință sau intenționalitate, ci doar o capacitate extinsă de generalizare și auto-învățare.

AGI nu există încă. Modelele actuale sunt **specializate** (narrow AI) și depind de seturi mari de date și resurse energetice uriașe. Totuși, tendința este clară: modelele generative devin din ce în ce mai autonome, capabile să planifice, să evalueze și să-și corecteze rezultatele. Aceste capacități marchează începutul erei **agenților autonomi** – programe care pot combina percepția, raționamentul și acțiunea într-un ciclu continuu de îmbunătățire.

Un **agent AI** poate analiza o problemă, căuta informații suplimentare, genera ipoteze, testa soluții și comunica rezultatele fără intervenție umană directă. În cercetarea medicală, astfel de agenți sunt folosiți deja pentru a descoperi noi combinații terapeutice sau pentru a planifica studiile clinice simulând scenarii complexe.

În următorul deceniu, se conturează integrarea inteligenței artificiale cu **Internetul Obiectelor (IoT)** și cu infrastructurile de date distribuite. Rețelele de senzori medicali, dispozitivele purtabile și echipamentele spitalicești conectate vor genera fluxuri continue de informații pe care sistemele AI le pot analiza în timp real. Un astfel de ecosistem va permite **învățarea continuă** – algoritmi vor putea să se perfecționeze din experiența zilnică, adaptându-se la particularitățile fiecărui pacient sau context clinic.

Această direcție duce către conceptul de **autoperfecționare controlată**: modele care își ajustează intern parametrii, dar sub supravegherea unor criterii etice și tehnice bine definite. În acest scenariu, sistemele medicale devin nu doar asistive, ci și reflexive – învățând din propriile decizii și oferind explicații tot mai precise.

Reglementări și etică

Progresul tehnologic rapid impune un cadru etic solid. În 2024, Uniunea Europeană a adoptat **AI Act**, primul set comprehensiv de reglementări dedicate inteligenței artificiale. Acesta clasifică aplicațiile AI în funcție de risc (minim, limitat, ridicat, inacceptabil) și impune cerințe stricte pentru sistemele utilizate în sănătate: transparență, explicabilitate, validare continuă și supraveghere umană obligatorie.

Dezvoltarea responsabilă a inteligenței artificiale presupune mai mult decât controlul tehnologic. Ea cere definirea clară a **responsabilității decizionale**, protejarea datelor sensibile, asigurarea echității algoritmice și educarea profesioniștilor care vor colabora cu aceste sisteme.

Privind înainte

Pe orizontul anilor 2030+, AI va deveni infrastructura invizibilă a medicinei: va analiza în fundal fluxurile de date, va ajusta automat tratamente personalizate și va dialoga natural cu pacientul. În loc să înlocuiască raționamentul medical, va amplifica capacitatea de înțelegere și anticipare.

AGI rămâne, pentru moment, o promisiune, dar drumul către ea trece inevitabil prin colaborarea om–mașină, prin standarde etice clare și printr-un echilibru între inovație și responsabilitate. În acest echilibru se află esența medicinei viitorului: **o inteligență extinsă, dar profund umană**, care folosește tehnologia pentru a îngriji mai bine, nu pentru a decide în locul omului.

De reținut

- **Decizia medicală asistată** transformă cunoștințele clinice în algoritmi care pot sprijini, dar nu substituie, raționamentul medicului.
- **Calitatea sistemelor** se evaluează prin sensibilitate, specificitate, AUC și calibrare, dar și prin relevanța clinică și beneficiul net.
- **Machine Learning** permite descoperirea automată a relațiilor din date, în timp ce **sistemele expert** și metodele euristice imită raționamentul specialistului.
- **Inteligența artificială generativă (GenAI)** – reprezentată de modele precum GPT-5, Claude, Gemini, Mistral sau DeepSeek – produce texte și explicații noi; eficiența ei depinde de prompturi clare și de integrarea controlată cu baze de date (RAG).
- **Halucinațiile** apar atunci când modelul „inventează” informații; pot fi reduse prin conectarea la surse verificate și validare umană.
- **Agenții autonomi** marchează începutul unei ere în care sistemele AI pot învăța și acționa în mod reflexiv, sub supravegherea principiilor etice.
- **Perspectivile 2030+** vizează fuziunea AI–IoT, învățarea continuă și reglementarea responsabilă (AI Act), în care AI devine infrastructura invizibilă a medicinei, amplificând, nu înlocuind, judecata umană.

Glosar de termeni

AI (Artificial Intelligence / Inteligență artificială) – ansamblu de metode și sisteme capabile să simuleze procese cognitive umane: percepție, raționament, planificare, învățare.

AGI (Artificial General Intelligence) – formă ipotetică de inteligență artificială cu capacitate generală de învățare și raționament, transferabilă între domenii.

AI Act – regulament adoptat de Uniunea Europeană în 2024, care stabilește clasificarea și cerințele pentru sistemele de inteligență artificială în funcție de nivelul de risc.

AIoT (Artificial Intelligence of Things) – integrarea inteligenței artificiale cu Internetul Obiectelor (IoT), pentru analiza și adaptarea în timp real a datelor colectate de dispozitive conectate.

Blockchain – tehnologie de stocare distribuită și securizată a datelor, bazată pe lanțuri criptografice de blocuri; utilizată în validarea tranzacțiilor și protecția datelor medicale.

CDSS (Clinical Decision Support Systems) – sisteme informatice care oferă recomandări clinice bazate pe ghiduri, algoritmi și date pacient-specifice.

Data mining – proces de extragere automată a cunoștințelor și modelelor din seturi mari de date.

Deep learning – ramură a machine learning-ului care folosește rețele neuronale profunde cu multiple straturi pentru analiza datelor complexe (imagini, sunet, text).

EHR / DES (Electronic Health Record / Dosar Electronic de Sănătate) – ansamblu electronic de date medicale standardizate, partajabile între instituții și niveluri de asistență.

EHDS (European Health Data Space) – inițiativă a Uniunii Europene pentru crearea unui spațiu comun al datelor de sănătate, destinat cercetării, inovării și asistenței medicale transfrontaliere.

GenAI (Generative Artificial Intelligence) – inteligență artificială capabilă să creeze conținut nou (texte, imagini, sunete) pornind de la modele învățate.

GPT (Generative Pre-trained Transformer) – arhitectură de model lingvistic bazată pe mecanismul de atenție, antrenată pe volume mari de text pentru generarea de conținut coerent.

Halucinație (în AI) – producerea de informații aparent plauzibile, dar factualmente incorecte, de către un model generativ.

Interoperabilitate – capacitatea sistemelor informatice de a comunica și schimba date într-un format comun, păstrând semnificația informației.

IoT (Internet of Things) – rețea de dispozitive fizice conectate (senzori, echipamente medicale, dispozitive portabile) care colectează și transmit date în timp real.

LLM (Large Language Model) – model de inteligență artificială antrenat pe volume masive de text, capabil să genereze și să interpreteze limbaj natural.

Machine Learning (ML) – metodă de inteligență artificială prin care un sistem învață automat din date pentru a face predicții sau clasificări.

Metode euristice – strategii de rezolvare a problemelor bazate pe experiență și aproximare, nu pe calcule exhaustive.

NLP (Natural Language Processing) – ramură a AI care se ocupă cu înțelegerea și generarea limbajului natural.

Prompt engineering – tehnica de formulare precisă a instrucțiunilor adresate unui model generativ pentru a obține rezultate relevante și corecte.

RAG (Retrieval-Augmented Generation) – metodă prin care un model generativ consultă o bază de date externă validată înainte de a produce un răspuns, reducând riscul de halucinație.

XAI (Explainable Artificial Intelligence) – direcție de cercetare dedicată creării de modele AI care pot explica în mod inteligibil raționamentul decizional.

Bibliografie selectivă

Shortliffe EH, Cimino JJ, editors. *Biomedical Informatics: Computer Applications in Health Care and Biomedicine*. 5th ed. London: Springer; 2021. 1037 p. <https://doi.org/10.1007/978-3-030-58721-5>

Coiera, E. (2015). *Guide to Health Informatics* (3rd ed.). CRC Press. <https://doi.org/10.1201/b13617>

Van Bommel JH, Musen MA, editors. *Handbook of Medical Informatics*. Springer-Verlag, Berlin, 1997.

Mihalas GI, Lungeanu D: *Informatică Medicală și Biostatistică*. Timișoara: Ed. Victor Babeș, 2009. Reprint 2011.

De Gruyter. Big data in the healthcare system: a synergy with artificial intelligence and blockchain technology. *J Integr Bioinform*. 2021;18(3):20210035. <https://www.degruyter.com/document/doi/10.1515/jib-2020-0035/pdf>

Hersh W. *Health Informatics: Practical Guide for Healthcare and Information Technology Professionals*. 8th ed. Informatics Education; 2022.

Mihalas GI. *Inteligența Artificială în Medicină. Ghid de conversație pentru medici, studenți și pacienți*. Ed. Victor Babeș Timișoara, 2025. ISBN 978-606-786-473-1

Hennessy JL, Patterson DA. *Computer Architecture: A Quantitative Approach*. 6th ed. Cambridge: Morgan Kaufmann; 2019. 936 p.

Awrahman BJ, Aziz Fatah C, Hamaamin MY. A Review of the Role and Challenges of Big Data in Healthcare Informatics and Analytics. *Comput Intell Neurosci*. 2022 Sep 29;2022:5317760. doi: 10.1155/2022/5317760.

Friedman CP, Wyatt JC. *Evaluation Methods in Biomedical Informatics*. 3rd ed. Springer; 2022.

Armitage, P., Berry, G., & Matthews, J. N. S. (2002). *Statistical methods in medical research* (4th ed.). Blackwell Science. doi:10.1002/9780470773666

European Health Telematics Association (EHTEL). *Interoperability and the Future of Digital Health in Europe*. Brussels: EHTEL; 2022.

<https://ehtel.eu/>

ISO/TC 215. *Health informatics — Interoperability and data exchange standards*. Geneva: International Organization for Standardization; 2023.

<https://www.iso.org/committee/54960.html>

European Commission. *European Health Data Space Proposal*.

COM(2022) 197 final; 2023. <https://eur-lex.europa.eu/legal-content/RO/TXT/HTML/?uri=CELEX:52022PC0197>

Lazcoz, G., Miguel, I. (2025). Is more data always better? On alternative policies to mitigate bias in Artificial Intelligence health systems. *Bioethics*, 39, 414–424. <https://doi.org/10.1111/bioe.13398>

Siontis, K.C., Noseworthy, P.A., Attia, Z.I. et al. Artificial intelligence-enhanced electrocardiography in cardiovascular disease management. *Nat Rev Cardiol* 18, 465–478 (2021). <https://doi.org/10.1038/s41569-020-00503-2>

Greenes RA, editor. *Clinical Decision Support: The Road to Broad Adoption*. Academic Press; 2023. DOI:10.1016/C2020-0-03560-7

Blezek DJ, Olson-Williams L, Missert A, Korfiatis P. AI Integration in the Clinical Workflow. *J Digit Imaging*. 2021;34(6):1435-1446. doi:10.1007/s10278-021-00525-3

Gyrard A, Abedian R et al. Lessons Learned From European Health Data Projects With Cancer Use Cases: Implementation of Health Standards and Internet of Things Semantic Interoperability *J Med Internet Res* 2025;27:e66273

Topol E. *Deep Medicine: How Artificial Intelligence Can Make Healthcare Human Again*. New York, NY: Basic Books; 2019. ISBN: 9781541644632.

Davenport T, Kalakota R. The potential for artificial intelligence in healthcare. *Future Healthc J*. 2019;6(2):94–8. doi: 10.7861/futurehosp.6-2-94

Hussein R, Gyrard A, Abedian S, Gribbon P, Martínez SA. Interoperability Framework of the European Health Data Space for the Secondary Use of Data: Interactive European Interoperability Framework-Based Standards Compliance Toolkit for AI-Driven Projects. *J Med Internet Res*. 2025;27:e69813. doi:10.2196/69813

Yu, P.; Xu, H.; Hu, X.; Deng, C. Leveraging Generative AI and Large Language Models: A Comprehensive Roadmap for Healthcare Integration. *Healthcare* 2023, 11, 2776. <https://doi.org/10.3390/healthcare11202776>

World Health Organization. *Ethics and governance of artificial intelligence for health*. Geneva: WHO; 2021. <https://www.who.int/publications/i/item/9789240029200>

European Commission. *Artificial Intelligence Act*. Off J Eur Union; 2024. <https://eur-lex.europa.eu/legal-content/RO/TXT/?uri=CELEX:32024R1689>

OpenAI. GPT-4 technical report. 2023. <https://cdn.openai.com/papers/gpt-4.pdf>

Anthropic. *Claude 3 Model Card*. Anthropic Research; 2024. <https://www.anthropic.com/news/claude-3-family>

Google DeepMind. *Gemini 1.5: Gemini 1.5: Unlocking multimodal understanding across millions of tokens of context*. 2024. <https://arxiv.org/html/2403.05530v2>.

Mistral AI. *Mistral 7B Technical Overview*. Mistral Research; 2024. <https://mistral.ai/news/announcing-mistral-7b>

Joshi, S. A Technical Review of DeepSeek AI: Capabilities and Comparisons with Insights from Q1 2025. *Preprints* 2025, 2025041676. <https://doi.org/10.20944/preprints202504.1676.v1>.

Esteva A, Chou K, Yeung S, Naik N, Madani A, Mottaghi A, Liu Y, Topol E, Dean J, Socher R. Deep learning-enabled medical computer vision. *NPJ Digit Med*. 2021 Jan 8;4(1):5. doi: 10.1038/s41746-020-00376-2.

Amann J, et al. Explainability for artificial intelligence in healthcare: a multidisciplinary perspective. *BMC Med Inform Decis Mak*. 2020; 20:310.

Note editoriale

Lucrarea a fost finalizată în cadrul Universității de Medicină și Farmacie „Victor Babeș” din Timișoara, în anul 2025, ca parte a activităților didactice și de cercetare desfășurate în domeniul *Informatica medicală și sănătate digitală*.

Volumul reflectă eforturile colective ale catedrei de Informatică și Biostatistică Medicală de a adapta conținutul educațional la provocările erei digitale, menținând totodată tradiția academică a școlii timișorene inițiate de Prof. dr. Gh. I. Mihalaș.

Textul a fost elaborat pe baza materialelor utilizate în predarea cursurilor și laboratoarelor pentru studenții Facultății de Medicină, completate cu exemple, studii de caz și reflecții rezultate din proiecte internaționale de inovare educațională și cercetare în domeniul inteligenței artificiale medicale.

Versiunea digitală a lucrării a fost redactată, editată și validată în Timișoara, în perioada ianuarie–octombrie 2025.

Lucrarea a fost publicată cu sprijinul financiar al Universității de Medicină și Farmacie „Victor Babeș” din Timișoara.

Toate drepturile asupra conținutului aparțin autorului. Reproducerea parțială este permisă doar cu menționarea sursei.