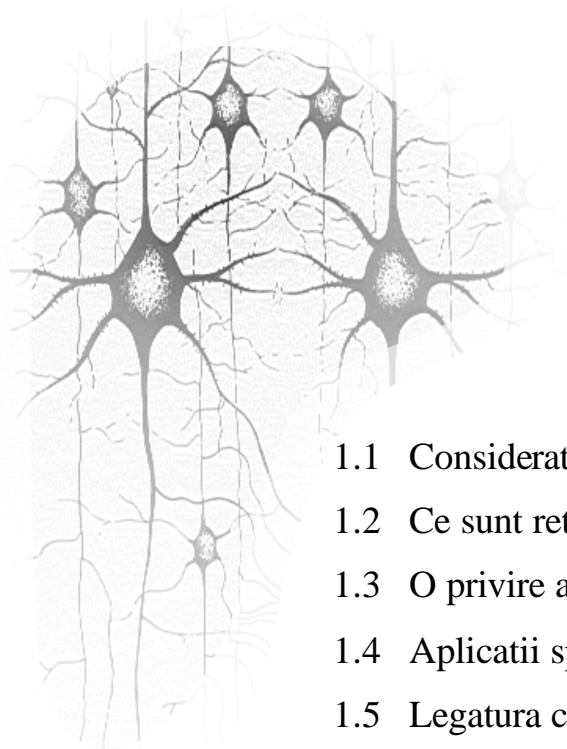


Capitolul 1

Introducere în teoria rețelelor neurale artificiale



- 1.1 Consideratii generale
- 1.2 Ce sunt rețelele neurale artificiale ?
- 1.3 O privire asupra creierului uman
- 1.4 Aplicatii specifice
- 1.5 Legatura cu alte domenii
- 1.6 Note istorice

Retele neurale, algoritmi genetici, sisteme fuzzy: iata numai câteva dintre notiunile care pâna nu demult pareau mai degraba desprinse dintr-un roman stiintifico-fantastic decât din cuprinsul unei publicatii stiintifice. Si totusi în zilele noastre atât cercetatori din universitati cât si din marile companii utilizeaza în mod curent astfel de tehnologii, într-un efort sustinut de a integra elemente de *inteligenta artificiala* în proiecte concrete. Fiecare dintre aceste directii de cercetare utilizeaza instrumente teoretice si terminologie specifice, prezinta deopotriava avantaje reale dar si limitari recunoscute si au fost introduse deja cu mai mult sau mai putin succes în circuitul comercial. În cele ce urmeaza vom face cunostinta cu subiectul central al acestei lucrari, cel al retelelor neurale artificiale. Scopul urmarit este de a ilustra motivatiile care justifica interesul pentru aceasta directie de cercetare, de a introduce primele elemente de terminologie si de a trece în revista o serie de aplicatii. Spre final vom parcurge câteva file de istorie, enumerând principalele momente care au jalonat evolutia acestui domeniu în ultimele decenii.

1.1 Consideratii generale

Desi nu exista o definitie general acceptata a retelelor neurale artificiale, majoritatea cercetatorilor sunt de acord ca acestea reprezinta ansambluri de elemente de procesare simple, interconectate prin canale de comunicatii prin care se propaga informatie numerica. Din perspectiva istorica, multe dintre ideile vehiculate în acest context sunt motivate de dorinta de a construi sisteme capabile sa rezolve cu succes sarcini uzuale pentru creierul uman precum înțelegerea vorbirii sau recunoasterea formelor. În fapt, aceasta abordare s-a dovedit utila în special pentru probleme dificil de formalizat sub forma unui algoritm (adica a unei "rețete" care sa garanteze rezultatul), situatie care presupune o înțelegere profunda a aplicatiei considerate. Astfel de situatii nu sunt de loc rare: sa ne închipuim numai usurinta cu care reusim sa descifram scrisul de mâna al unei persoane necunoscute sau cea cu care recunoastem prieteni vechi chiar daca nu iam mai întâlnit din scoala primara. Majoritatea retelelor neurale utilizeaza mecanisme pe baza carora intensitatea legaturilor dintre neuroni sunt ajustate în functie de calitatea raspunsului la stimuli externi. Ajungem astfel la principala trasatura a acestor sisteme, anume capacitatea de *a învăta pe baza de exemple*, folosind "experienta" anterioara pentru a-si îmbunatatii permanent performantele, dar si de a oferi un anumit grad de generalizare, care se traduce printr-un raspuns adecvat la informatii de intrare care nu au fost folosite în faza de "antrenare". Iata un exemplu foarte simplu: parintii folosesc deseori prilejul unor plimbari prin parc pentru a-i învăta pe copii rasele de câini. Dupa ce va fi înțeles cum arata un dalmatian, copilul

va fi în stare sa recunoasca un astfel de exemplar chiar si atunci când îl vede în celebrul film de desene animate!

Exista câteva motive întemeiate pentru a considera rețelele neurale ca o solutie atractiva într-o serie întreaga de aplicatii practice importante, dintre care amintim:

- acestea pot actiona ca module de tip *black-box* în situatiile în care avem la dispozitie un volum mare de date, fara a putea spune prea multe despre procesul care le-a generat. De multe ori, desi identificarea unei dependente între marimile de intrare si o anumita informatie de interes ar fi extrem de utila, nu beneficiem de modele adecvate sau de valori ale parametrilor acestora. Un exemplu concludent este oferit de aplicatiile financiare: valoarea unei actiuni sau a unui indice bursier este în mod evident dependenta de ansamblul informatiilor existente pe piata pâna la momentul considerat, însa modele analitice pur si simplu nu exista. Rețelele neurale sunt capabile sa descopere astfel de dependente “ascunse” pornind numai de la baza de date disponibila, fara a impune constrângeri de modelare. Scopul este atins folosind algoritmi specifici, care modifica valorile interconexiunilor dintre neuroni astfel încât sa “forteze” ca raspunsul rețelei sa se apropie cât mai mult de cel dorit.
- în urma unui proces de învățare reusit, rețelele neurale tolereaza în mod remarcabil diferente (uneori, apreciabile) între datele aplicate la intrare în procesul de operare si cele “vazute” în etapa de antrenare. Dar acesta reprezinta si modul natural de functionare al creierului uman: odata ce am învățat sa citim suntem de regula capabili sa înțelegem scrisul de mâna al unor persoane necunoscute (chiar si al unui farmacist!). Aceasta reprezinta o consecinta a asa-numitei *capacitati de generalizare* a rețelelor neurale, care exprima posibilitatea acestora de a oferi un raspuns corect chiar daca la intrare se aplica versiuni incomplete, zgomotoase sau distorsionate ale informatiilor folosite în antrenare.
- aplicatii extrem de diferite pot fi abordate folosind practic acelasi sistem, fara a fi necesara reproiectarea completa. Mai mult, extinderea acestei tehnologii este facilitata de prezenta pe piata a unor circuite integrate specializate si chiar a unor placi compatibile PC, care ofera performante de viteza si precizie suficiente pentru a permite implementarea unor algoritmi de procesare complecsi, limitati în trecut numai la utilizarea în programe de simulare dedicate. O serie de aplicatii practice realiste, care depasesc cadrul restrâns al asa-numitelor *toy problems*, constituie deja obiectul de activitate al unor firme de mare succes. În paralel, au fost dezvoltate si lansate în circuitul comercial o serie de simulatoare puternice si flexibile, un exemplu concludent în acest sens fiind oferit de produsul firmei americane *NeuroDimension* denumit *NeuroSolutions* [131].

1.2 Ce sunt rețelele neurale artificiale ?

În locul unei definiții academice (în fapt nici nu există una general acceptată) a acestei noțiuni, preferăm să ne plasăm în postura unor spectatori care asistă la o *discuție virtuală* purtată între câțiva dintre cei mai cunoscuți specialiști în domeniu. “Răspunsurile” sunt preluate din cuprinsul unor lucrări de specialitate des citate [76], [79], [103] și ilustrează cu claritate cele două caracteristici de bază ale rețelelor neurale artificiale, anume *structura paralela distribuită* și *capacitatea de a învăța*. În mod concret, cele expuse în continuare răspund la următoarele întrebări:

1. Ce este o rețea neurală artificială ?
2. Care este legătura cu creierul biologic ?
3. Unde se aplică această tehnologie ?

Teuvo Kohonen (*Helsinki University of Technology, Finland*):

Retelele neurale artificiale reprezintă ansambluri de elemente de procesare simple (de regulă, adaptive), puternic interconectate și operând în paralel, care urmăresc să interacționeze cu mediul înconjurător într-un mod asemănător creierelor biologice.

Următoarele aspecte sunt comune atât rețelelor neurale artificiale cât și celor biologice:

- *reprezentarea și procesarea informației în formă analogică (care permite desfășurarea în paralel a mai multor procese în mod asincron)*
- *abilitatea de a efectua operațiuni de natură statistică asupra datelor de lucru (operațiuni de mediere, de regulă condiționată)*
- *corecție de erori și degradare graduală a performanțelor la apariția acestora*
- *capacitate de adaptare la un mediu în continuă schimbare*

Retelele neurale artificiale s-au impus ca instrumente puternice de analiză a unor volume mari de date experimentale, generate de procese fizice ghidate de legi necunoscute, pentru care aceste sisteme pot oferi modele adecvate. Această tehnologie nu își propune ca obiectiv principal obținerea unor circuite motivate anatomic, ci funcțional, astfel încât să beneficiem de metode de procesare eficiente complementare celor tradiționale, disponibile sub formă de algoritmi de calcul și componente hard și soft.

Simon Haykin (Mc Master University, Canada):

O rețea neurală reprezintă un sistem de procesare paralel care prezintă o capacitate naturală de a acumula experiență și de a o folosi. Se aseamăna cu creierul natural sub două aspecte:

- 1. Cunoștințele sunt dobândite în urma unui proces de învățare.*
- 2. Cunoștințele sunt stocate în valorile interconexiunilor dintre neuroni (denumite ponderi, sau sinapse).*

Interesul pentru sinteza unor rețele neurale artificiale este motivat de performanțele creierelor naturale, care oferă dovada concretă că modul de calcul paralel dublat de toleranța la erori este nu numai posibil, dar și rapid și eficient. Astfel, din punct de vedere ingineresc, neurobiologia poate fi privită ca o "pepinieră" de idei noi, posibil de utilizat pentru rezolvarea unor probleme prea complicate pentru metodele tradiționale.

Un exemplu concret de întreprindere a abordării strict tehnice cu cea biologică îl constituie implementarea așa-numitelor circuite integrate "neuromorfice", bazate pe modele ale retinei sau al urechii interne.

Robert Hecht-Nielsen (University of California at San Diego, USA):

O rețea neurală este o structură de procesare distribuită, operând în paralel, formată din procesoare simple (care posedă memorie locală și efectuează operații dependente de informații localizate spațial) interconectate prin legături unidirectionale. Fiecare procesor elementar are o singură ieșire, care este distribuită către un număr nelimitat de alte asemenea procesoare. Caracterul local al operațiilor efectuate se referă la condiția că valoarea instantanee a răspunsului fiecărui neuron elementar să depindă exclusiv de valorile instantanee ale semnalelor de intrare și de valorile interconexiunilor aferente acestora.

Rețelele neurale artificiale oferă o bază solidă pentru proiectarea unor sisteme complexe de prelucrare a semnalelor. Au fost propuse deja o serie întreagă de module funcționale care realizează sarcini precise și care pot fi interconectate sub forma unor arhitecturi flexibile, pot fi supuse unui proces automat de ajustare a parametrilor specifici și testate cu baze de date corespunzătoare unor aplicații practice concrete. Când o astfel de abordare automatizată la nivel de design de detaliu se va impune, rolul proiectantului uman se va concentra pe aspectele globale, la nivel de schema-bloc ale sistemului.

1.3 O privire asupra creierului uman¹

Creierul uman reprezintă probabil una dintre cele mai complexe structuri cunoscute, capabil de performanțe încă departe de a fi egalate de “rudele” sale digitale. Chiar dacă vehiculele moderne pot fi dirijate de pilotul automat sau campionul mondial la șah Garry Kasparov întâmpina deja dificultăți în fața supercomputerelor IBM, este greu de prevăzut orizontul de timp în care un sistem de calcul artificial se va orienta cu aceeași siguranță și precizie precum un om aflat pentru prima oară într-un oraș necunoscut sau va identifica cu acuratețe chipuri, glasuri, atitudini. Rezolvarea fără dificultăți a unor astfel de sarcini complicate este produsul unei evoluții de multe milioane de ani, deși unele structuri cerebrale au apărut relativ recent. Spre exemplu, acum 100000 de ani creierul uman avea o greutate de aproximativ 3 ori mai mică decât în prezent. Diferența provine în mare măsură din dezvoltarea *cortex*-ului, care reprezintă învelișul structurii celei mai evaluate de organizare a creierului (*cerebrum*).

În fapt, acum 5 milioane de ani *cortex*-ul omului primitiv era organizat în regiuni având o lățime mai mică de 1 mm, care conțineau câteva milioane de celule nervoase. Acum 100000 de mii de ani această structură a cunoscut o expansiune rapidă, astfel încât *cortex*-ul omului modern include cam două treimi din numărul total de neuroni și cântărește aproximativ 1,2 kg.

Creierul uman se compune din 3 părți distincte:

- a) *creierul inferior*: controlează respirația, bătăile inimii și digestia, și include cerebelul (creierul mic), “responsabil” pentru simțuri și coordonarea mușchilor.
- b) *creierul mijlociu*: asigură legătura dintre creierul inferior și zonele denumite *thalamus* și *hypothalamus*, cu rol în transmiterea informațiilor și coordonarea acțiunilor. O altă componentă, sistemul limbic, este direct implicată în controlul temperaturii corpului și al emoțiilor, în lansarea unor comenzi, precum și în aspectul fundamental al memoriei, prin regiunea denumită *hippocampus* (leziuni în această zonă conduc la amnezie).
- c) *creierul mare*: este “sediul” funcțiilor de nivel înalt, având zone clar specializate precum centrul vederii sau al celui motor. Este format din două emisfere acoperite de o suprafață cu numeroase circumvoluțiuni (*cortex*-ul), de aproximativ 2 mm grosime și având o arie desfășurată de circa 1,5 m².

¹ Informațiile din acest paragraf sunt disponibile pe pagina www.brain.web-us.com

Creierul uman poate fi comparat cu un sit arheologic, în care stratul de la suprafața conține structurile cele mai recente (cortex-ul), iar în adâncime regăsim “mostenirea” rezultată din evoluția pe parcursul a milioane de ani. În mare măsură, creierul inferior și mijlociu grupează funcții care se fac “din instinct” (nu trebuie să ne aducem aminte să respirăm!), fără a implica elemente conștiente.

Există o anumită simetrie între cele două emisfere, evidențiată prin prezența a câte 2 lobi occipitali, parietali, respectiv frontali, ca în Fig. 1.1. Simetria nu este însă completă, astfel încât spre exemplu centrul vorbirii apare numai în emisfera stângă. Este interesant de menționat că lobi parietali conțin o “hartă” a întregului corp: grupe formate dintr-un număr variabil de neuroni sunt dedicate unor regiuni distincte, astfel încât este posibil să identificăm comod “atenția” acordată în creier fiecărei zone. Lobi frontali ocupă aproximativ 29% din suprafața cortex-ului (spre deosebire de 3,5% la șobolani sau 17% la cimpanzei) și oferă din acest punct de vedere un indicator al gradului de evoluție a speciei umane. În cele mai multe cazuri, emisfera stângă (care controlează partea dreaptă a corpului) este dominantă în luarea unor decizii în raport cu stimuli provenind din mediul înconjurător. Aceasta controlează vorbirea și funcțiile care presupun cunoaștere, fiind asociată cu ceea ce este cunoscut drept “conștiința de sine”. Emisfera dreaptă (care controlează partea stângă a corpului) este responsabilă cu “gestionarea” atenției, a orientării, precum și cu detectia semnalelor acustice complexe. Cele două emisfere comunică între ele, însă acționează ca 2 procesoare cu funcții complementare.

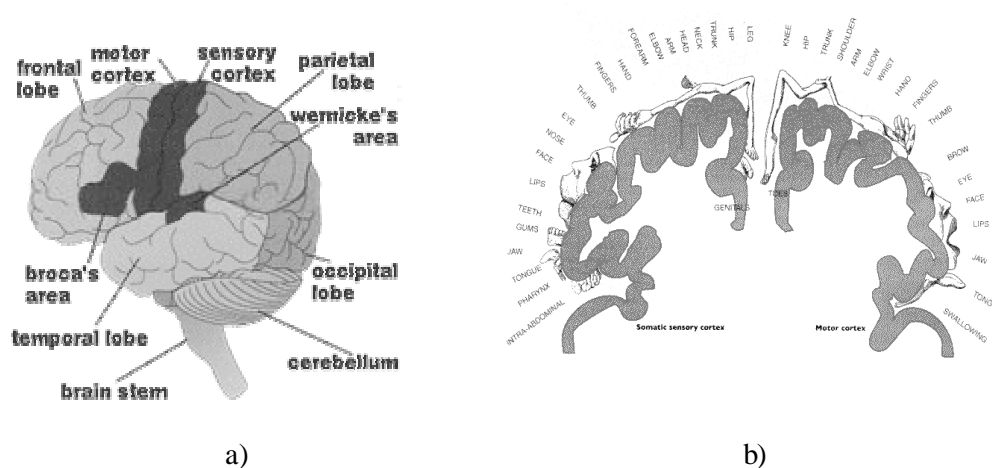


Fig. 1.1: a) structura creierului uman; b) harta cortex-ului

“Caramida” elementara din structura creierului o reprezinta celula nervoasa, denumita pe scurt neuron. În Fig. 1.2 este schitata o astfel de celula, care include corpul celulei (*soma*), dendritele si axonul. Dendritele receptioneaza semnalele provenind de la axonii altor neuroni si le conduc spre corpul celulei. Spatiul dintre un axon si o dendrita se numeste sinapsa. În creierul uman se gasesc aproximativ 10^{11} neuroni (adica de ordinul de marime al numarului de stele din Calea Lactee!), iar fiecare neuron poate primi semnale de la 1000-10000 de “vecini”. În functie de forma acestora se disting 34 de tipuri diferite de neuroni, iar din punct de vedere functional regasim 100 de tipuri. Atunci când semnalul total receptionat de un neuron prin dendritele sale (denumit *activitatea* celulei) depaseste o anumita valoare de prag se emite un asa-numit potential de actiune (*action potential*), sub forma unui puls electric cu amplitudinea de 70 mV, cu durata de 1 ms, care se propaga de-a lungul axonului cu o viteza de 120 m/s. Când impulsul ajunge în dreptul unei sinapse acesta se transforma într-un set de “semnale” chimice (neurotransmitatori) care se propaga prin spatiul care separa cei 2 neuroni, iar la contactul cu membrana “destinatarului” semnalul este reconvertit la forma electrica. Sinapsele pot fi excitatoare, atunci când conduc la cresterea nivelului de activitate intern al celulei, sau inhibitoare în cazul în care reduc acest nivel. Studiile au aratat o comportare binara (de tip comparator) a celulei nervoase: sub un anumit prag de activitate neuronul nu produce nici un semnal, iar peste acest prag emite potentialul de actiune, dupa care se “reseteaza”. Pe masura ce creste nivelul de activitate potentialul de actiune își maresc frecventa, nu însă si amplitudinea. La valori foarte ridicate ale activitatii nu se mai observa cresteri nici ale frecventei si nici ale amplitudinii. Din punct de vedere matematic, dependenta dintre nivelul de activitate si frecventa de emisie a potentialului de actiune poate fi modelata printr-o functie denumita *sigmoidala*:

$$f(x) = \frac{1}{1 + e^{-a(x-T)}} \quad (1.1)$$

în care x desemneaza activitatea totala, T este valoarea de prag, iar constanta a controleaza derivata în origine a functiei $f(x)$. Este important de subliniat ca valoarea interconexiunii dintre doi neuroni este “modulata” de comportarea ansamblului acestora. Astfel, o regula celebra elaborata de catre cercetatorul american D. Hebb indica faptul ca legatura dintre neuroni devine mai puternica daca acestia tind sa emita simultan potentialul de actiune. O observatie fundamentala este cea potrivit careia memorarea informatiilor se face nu prin stocarea la nivelul neuronului elementar, ci chiar în valorile interconexiunilor.

Observatie: “Mesajele” dintre neuroni sunt modulate în frecvența de transmitere a pulsurilor, care poate ajunge pînă la cîteva sute de Hz. Aceste valori sunt cu cîteva ordine de mărime mai mici decît cele disponibile în tehnologiile actuale și totuși sarcini extrem de complicate (de exemplu, identificarea unei persoane cunoscute) sunt rezolvate foarte rapid, de obicei în cîteva sute de milisecunde. Pentru ca un “circuit” neural format din “dispozitive” cu viteza de operare de cîteva milisecunde să fie capabil de asemenea performante este obligatoriu ca acesta să opereze *în paralel* și, în plus, cantitatea de informație transmisă să fie mică. Rezultă de aici că informația semnificativă nu se transmite în mod direct, ci este “stocată” în masa distribuită a interconexiunilor dintre neuroni. Principiul structurii dense a legăturilor dintre neuroni a fost preluat și în teoria rețelelor neurale artificiale, motiv pentru care aceste sisteme sunt denumite și *rețele conexiuniste*. În concluzie, “cheia” rezolvării unor sarcini complicate de către creierul uman constă în utilizarea calculului paralel și a reprezentării distribuite.

Multe dintre caracteristicile creierului uman nu se regăsesc la calculatoarele digitale actuale. Acestea sunt fără îndoială rezultatul îndelungatei evoluții naturale și includ capacitatea de a învăța din experiență și de a folosi cunoștințele acumulate în contexte noi, procesarea paralelă și reprezentare distribuită a informației, toleranța “defecțiunilor” și consumul energetic redus. În Tabelul 1.1 se prezintă o analiză comparativă a celor două principii de calcul în funcție de principalii factori de interes:




Fig. 1.2: Neuronul elementar

Tabelul 1.1: Comparatie între calculatoarele digitale si rețelele neurale

Criteriul	Calculatoare digitale	Retele neurale
<i>Procesor</i>	Complex, de viteza ridicata, utilizat în arhitecturi care includ un numar redus de astfel de componente	Simplu, de viteza scazuta, prezent în numar foarte mare
<i>Principiu de operare</i>	<i>Deductie:</i> se aplica reguli cunoscute asupra datelor de intrare pentru a obtine raspunsul	<i>Inductie:</i> se utilizeaza datele de intrare si de iesire pentru a identifica regulile care le unesc
<i>Mod de calcul</i>	Centralizat, sincron si serial	Colectiv, asincron si paralel
<i>Memoria:</i>	Separata de procesor, centralizata si adresabila prin locatie	Integrata în procesor, distribuita si adresabila prin continut
<i>Fiabilitate:</i>	Nu tolereaza defectiunile	Tolereaza defectiunile datorita redundantei si a “dispersarii” sarcinilor
<i>Viteza de operare</i>	Ridicata (microsecunde).	Scazuta (fractioni de milisecunda).
<i>Aplicabilitate</i>	Utilizabile numai daca exista algoritmi (“rețete” de rezolvare) bine definiti si datele de intrare sunt precise	Utilizabile chiar în absenta unor algoritmi, sau folosind date incomplete, zgomotoase sau distorsionate

Multe elemente de terminologie specifice au fost preluate în mod natural si în literatura dedicata sistemelor artificiale. Este totusi important sa subliniem cu claritate diferentele care separa principiile de functionare ale creierelor naturale de cele ale calculatoarelor digitale clasice [102]:

- rețelele neurale biologice *nu* utilizeaza principiile de calcul ale calculatoarelor digitale. Dupa cum se stie calculul digital poate fi sincron sau asincron. Daca creierul ar functiona asincron ar trebui ca durata impulsurilor emise de neuroni sa fie variabila, pentru ca nivelele logice sa poata fi mentinute pe durate nedefinite de timp, fapt care

nu se observa în practica. Dacă funcționarea ar fi sincronă ar fi necesar un "ceas" global, care de asemenea nu a fost pus în evidență. Observația fundamentală este că funcționarea neuronilor reali nu oferă precizia și stabilitatea necesare pentru a defini funcții logice, deci creierul este de fapt un "calculator" analogic.

- rețelele neurale biologice *nu* utilizează algoritmi de calcul sau coduri de control. Un algoritm exprimă în mod uzual un calcul recurent, care presupune menținerea definiției unor funcții pentru o perioadă oarecare de timp. Datorită problemelor de stabilitate amintite anterior asemenea instrucțiuni sau coduri nu ar putea fi menținute pe durate de timp mari. Rezultă de aici că principiile de calcul inspirate de funcționarea creierului pot constitui o *alternativă la calculul algoritmic actual*.

1.4 Aplicatii specifice

Se pot identifica două direcții distincte înspre care este canalizată atenția cercetătorilor din domeniul rețelelor neurale. Prima o reprezintă identificarea unor modele plauzibile din punct de vedere biologic pentru neuronii elementari și structura de interconexiuni dintre aceștia. Interesul este justificat de preocupările pentru studierea creierelor naturale și de nivelul tehnologic actual, în speranța că într-o zi vom putea reproduce artificial performanțele remarcabile ale acestora. Cea de-a doua, pe care am putea-o denumi "inginerească", își propune un scop mai puțin ambițios dar la fel de necesar, anume **identificarea unor principii de procesare suficiente de simple și robuste, dependente de un număr relativ restrâns de parametri și care să poată fi folosite pentru rezolvarea unor probleme concrete.**

Gama aplicațiilor în care se utilizează rețelele neurale artificiale este extrem de vastă, extinzându-se mult în afara preocupărilor legate de tehnica în general și de electronica în particular. În ultimii ani au fost raportate rezultate foarte încurajatoare privind folosirea acestora în medicina, finanțe sau construcția de automobile și viitorul va demonstra cu siguranță înmulțirea și diversificarea acestor exemple. Această abordare s-a dovedit utilă și în cazul unor probleme "clasice", ca de exemplu conversia analog-numerică sau calculul de transformate liniare. În Fig. 1.3 și Tabelul 1.2 prezentăm câteva categorii de aplicații în care rețelele neurale au fost utilizate cu succes, dovedindu-se superioare soluțiilor clasice, cu observația că cele mai multe dintre acestea vor fi ilustrate prin exemple concrete pe parcursul capitolelor următoare:

- **Clasificare:** o problemă de clasificare urmărește încadrarea unei anumite informații de interes într-o categorie dintr-o listă predefinită. Exemple practice întâlnim în recunoașterea caracterelor scrise de mână, în analiza semnalelor biomedicale, în prelucrarea semnalelor radar. Diversele clase sunt separate de așa-numite *suprafețe de decizie*, ale caror forme pot fi foarte complicate. Aplicațiile

de clasificare presupun doua etape: reprezentarea convenabila a informatiilor de intrare (extragerea de trasaturi semnificative, neredundante) si luarea propriu-zisa a deciziei de alocare a "etichetei" corespunzatoare.

- **Aproximare functionala:** având la dispozitie un set *limitat* de perechi de date intrare-iesire generate de o functie necunoscuta scopul urmarit consta în estimarea cât mai exacta a dependentei functionale care exprima legatura dintre aceste informatii. În statistica matematica aceasta aplicatie este denumita *regresie* si beneficiaza de unele rezultate importante în special în cazul dependentelor liniare. În mare masura abordarea neurala se bazeaza pe existenta unor teoreme de aproximare universala specifice anumitor tipuri de retele si ofera cadrul de rezolvare al unor categorii importante de aplicatii precum cele de identificare de sistem, clasificare sau predictie.
- **Predictie:** scopul unei aplicatii de predictie este de a pune la dispozitie o valoare viitoare a unei informatii de interes folosind date cunoscute numai pâna la momentul de timp considerat. În aceasta categorie sunt incluse aplicatiile financiare, analiza fenomenelor meteorologice, studiul consumului energetic. Unul dintre motivele care justifica abordarea neurala este ca tehnicile de predictie liniara prezentate pe larg în literatura nu conduc la rezultate satisfacatoare în astfel de aplicatii importante.
- **Optimizare:** numeroase probleme concrete necesita identificarea unui set de valori ale unor parametri astfel încât o anumita informatie de interes (denumita functie obiectiv sau functie de cost) sa atinga valori extreme. Astfel de aplicatii pot fi extrem de dificile, în special daca functia de optimizat este supusa unor constrângeri sau daca problema poate avea mai multe solutii. Un caz particular îl reprezinta asa-numitele probleme de optimizare *combinationale*, la care setul de parametri poate capata numai valori discrete, dintr-un set predefinit. În unele situatii este suficient ca solutia obtinuta, desi suboptimala, sa asigure un compromis rezonabil între calitate si timpul de calcul necesar.
- **Memorie asociativa:** în memoriile clasice continutul unei locatii este accesat prin adresa corespunzatoare, care nu are nici o legatura cu informatia stocata. În plus, orice eroare în precizarea adresei are ca efect recuperarea unei informatii complet diferite. Spre deosebire de acest caz, o memorie asociativa este *adresabila prin continut*, în sensul ca recuperarea informatiei de interes se face furnizând nu o adresa, ci o versiune incompleta, distorsionata sau zgomotoasa chiar a informatiei stocate.

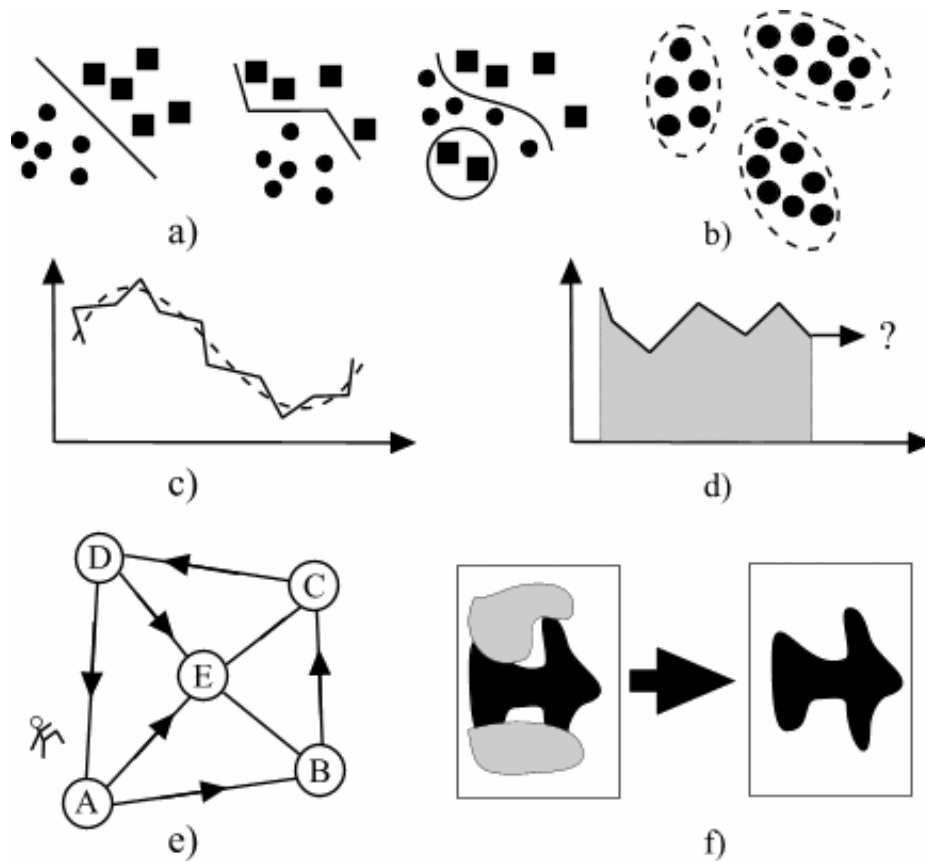


Fig. 1.3: Aplicatii ale retelelor neurale artificiale: a) clasificare; b) grupare (*clusterizare*); c) aproximare functionala; d) predictie; e) optimizare; f) memorie asociativa

Tabelul 1.2: Principalele tipuri de rețele neurale artificiale

Denumirea rețelei	Tipul arhitecturii	Algoritm de învățare	Tipul variabilelor	Aplicatii specifice
Perceptron	FF	S	A, D	Clasificare
Perceptron multistrat	FF	S	D	Recunoastere de forme, modelare de sistem
ART	REC	N	A, D	Prelucrarea semnalelor radar
Hopfield	REC	fara învățare	A, D	Optimizare, Conversie A/D
Kohonen	FF	N	D	Prelucrare de vorbire
BAM	REC	fara învățare	A, D	Memorie asociativa
Madaline	FF	S	D	Prelucrare adaptiva de semnal
Masina Boltzmann	FF	S	D	Recunoastere de forme
Neocognitron	FF	S	D	Recunoastere de caractere scrise de mâna
Hamming	FF+REC	fara învățare	D	Optimizare
RBF	FF	S	D	modelare de functii neliniare, egalizare

Legenda: FF - *feedforward*; S - învățare supravegheata; A - analogic
REC - recurenta; N - învățare nesupravegheata; D - discret
ART – Adaptive Resonance Theory; BAM – Bidirectional Associative Memory;
RBF – Radial Basis Functions

În pofida entuziasmului legat de acest domeniu manifestat mai ales în ultimii 10 ani, care uneori tinde sa ne duca cu gândul mai degraba la literatura stiintifico-fantastica, este important sa subliniem ca aceasta tehnologie nu este general aplicabila si rezultatele obtinute într-o problema concreta nu sunt neaparat superioare unei tratari "ortodoxe", prin metode clasice (de exemplu, statistice). Mai mult, exista situatii în care tratarea clasica si punctul de vedere "neural" sunt intim legate, ca de exemplu în cazul retelelor recurente de tip gradient (în care se utilizeaza intensiv stabilitatea în sens Liapunov) sau în prelucrarea de semnal vocal, unde clasificatoare neurale utilizeaza informatii oferite de modele Markov ascunse (*Hidden Markov Models - HMM*).

Observatia fundamentala care se poate face în legatura cu acest domeniu este ca retelele neurale sunt utile în aplicatii pe care le-am putea denumi "orientate pe date", adica la care beneficiem de un volum mare de rezultate experimentale de genul unor perechi intrare-iesire, fara sa putem spune prea multe despre sistemul sau procesul care le-a generat. Din acest punct de vedere, unele operatii de prelucrare intermediara a datelor, ca de exemplu normalizari, extragere de trasaturi semnificative (*feature extraction*), grupari (*clustering*) pot conduce la îmbunatatiri sensibile ale performantelor. De asemenea, în cazul modelarii/identificarii de sisteme a caror natura are un aspect neliniar intrinsec, abordarea "neurala" conduce la rezultate net superioare tratarii liniare (de exemplu în cazul egalizoarelor de canal în transmisiuni de date sau în analiza seriilor de timp, în particular a celor haotice). În unele aplicatii de prelucrare de imagine sau de control retelele neurale pot înlocui algoritmi de calcul complicati sau nu suficient de rapizi. În recunoasterea de forme, mai ales în cea a caracterelor scrise de mâna si, respectiv, în recunoasterea vorbirii, retelele neurale se dovedesc indispensabile în obtinerea unor rezultate semnificative.

Desi în majoritatea lucrarilor aparute în literatura de specialitate se utilizeaza intensiv simularea pe calculator este important sa subliniem ca un beneficiu real se poate capata numai prin implementarea solutiilor propuse, folosind circuite VLSI sau optice. O problema majora o constituie din acest punct de vedere modalitatea de a asigura compatibilitatea cu *hardware*-ul existent.

Prezentam în continuare câteva aplicatii concrete care ilustreaza aria larga de aplicabilitate a acestei tehnologii, cu mentiunea ca un numar special al *IEEE Transactions on Neural Networks* aparut în iulie 1997 a fost dedicat acestui subiect:

- detectia utilizarii frauduloase a cartilor de credit [54]: din 1996 functioneaza în Spania sistemul Minerva, care înglobeaza un clasificator neural capabil sa identifice cu mare probabilitate operatiunile frauduloase desfasurate cu carti de credit VISA. Sistemul face fata cu succes celor doua cerinte specifice acestei aplicatii, anume timpul mic de raspuns si volumul imens de tranzactii ce trebuie

analizate. Suportul teoretic este oferit de varianta neliniara a asa-numitei analize discriminatorii de tip Fisher.

- aplicatii financiare [131]: firma americana *NeuroDimension* a elaborat produsul software denumit *TradingSolutions* destinat unei categorii largi de aplicatii din domeniul financiar precum predictia indicatorilor bursieri, a valorii actiunilor cotate sau a dobânzilor, alcatuirea unui portofoliu de investitii si elaborarea unei strategii de actiune la bursa. Produsul este bazat pe utilizarea simulatorului *NeuroSolutions*, care înglobeaza o paleta extrem de larga de arhitecturi si algoritmi de antrenare inclusi într-un mediu de operare flexibil, intuitiv si simplu de manevrat.
- procesarea peliculelor de film [186]: firma americana *Silicon Recognition* produce un circuit VLSI specializat în operatii de prelucrare de imagine cu performante remarcabile. Acest circuit reprezinta materializarea conceptului denumit ZISC (*Zero Instruction Set Computer*) si include în structura sa o retea neurala denumita RBF (*Radial Basis Functions*) cu 36 de neuroni, expandabila nelimitat prin simpla interconectare a unor circuite similare. Conceptul, considerat revolutionar, asigura o viteza de operare de 8,6 GB/s, o frecventa de lucru redusa (33 MHz) si compatibilitate cu *hardware*-ul uzual. Circuitul a fost utilizat cu succes în prelucrarea peliculelor de film deteriorate, în aplicatii de recunoastere de caractere scrise de mâna, precum si de control al calitatii fabricarii circuitelor integrate.
- industria alimentara [32]: o retea neurala cu rol de clasificator a fost utilizata pentru analiza cleiului de stejar folosit în industria viticola pentru etanseizarea sticlelor de vin. Aplicatia este extrem de dificila deoarece trebuie identificata cu precizie prezenta oricaror crapaturi, gauri sau eventuale insecte si încadrarea corecta a probei analizate într-una dintre cele 8 categorii acceptate. În aceeași arie de interes se încadreaza si sistemul realizat de catre firma *Hecht-Nielsen Corporation* folosit la sortarea automata a merelor pe categorii de calitate.
- navigare automata: sistemul ALVINN (*Autonomous Land Vehicle In a Neural Network*) [144] primeste drept intrare imagini ale traseului de urmat si furnizeaza drept iesire directia pe care trebuie sa se miste vehiculul considerat. Este folosita o retea multistrat având 1217 neuroni pe stratul de intrare, 29 de neuroni pe stratul ascuns si 46 de neuroni de iesire. Baza de date de antrenare a constat din 1200 de imagini reprezentând diverse combinatii de trasee, curbe, conditii de iluminare si nivele de distorsionare. Rezultatele raportate au fost comparabile cu cele obtinute de cele mai performante sisteme de navigare automata traditionale, cu avantajul unei durate a procesului de antrenare incomparabil mai reduse si cu posibilitatea îmbunatatirii performantelor în urma constatarii unor erori de navigare.

Retelele neurale si politica

În campania pentru alegerile prezidentiale din Statele Unite din 1968, cu ocazia Conventiei Partidului Democrat desfasurata la Chicago au avut loc confruntari violente între politie si un grup de demonstranti, generate în principal de comportamentul agresiv al unor ofiteri. Pentru a preveni repetarea unor incidente asemanatoare, în preajma Conventiei similare desfasurate în 1996, Departamentul de Politie din Chicago a utilizat o retea neurala pentru a identifica politisti capabili de a provoca conflicte. Iata un citat din ziarul *Scientific American*, din decembrie 1994:

“The (neural network) program forecasts whether each of the 12,500 officers on the force is likely to behave in a manner similar to nearly 200 colleagues who were dismissed or resigned under investigation during the last five years for actions ranging from insubordination criminal misconduct.”

Un total de 91 de ofiteri au fost identificati si îndrumati spre un program de reeducare. Sindicatul politistilor a contestat concluziile studiului deoarece retea neurala nu oferea în mod explicit nici o motivatie asupra rezultatului furnizat.

1.5 Legatura cu alte domenii de cercetare

Retelele neurale artificiale sunt parte componenta a asa-numitelor *sisteme cognitive*, care reprezinta o colectie de tehnologii informatice *inspirate* de mecanismele care sunt utilizate de creierul uman în prelucrarea semnalelor receptionate, în procesul gândirii, în luarea unor decizii, precum si de principiile evolutiei naturale. În aceeasi categorie sunt incluse sistemele *fuzzy*, algoritmi genetici si sistemele expert (Fig. 1.4).

Pe de alta parte teoria retelelor neurale artificiale reprezinta un exemplu de arie de cercetare interdisciplinara. Un studiu aprofundat al acestui domeniu este de neconceput fara cunostinte de neurofiziologie, psihologie, matematica, fizica statistica, informatica, teoria sistemelor, microelectronica. Toate aceste discipline comunica activ cu teoria retelelor neurale, oferind suport teoretic si experimental si

beneficiind de instrumentele de analiza proprii tehnologiilor inteligente. O imagine intuitiva asupra legaturii cu alte domenii de cercetare se prezinta în Fig. 1.5.

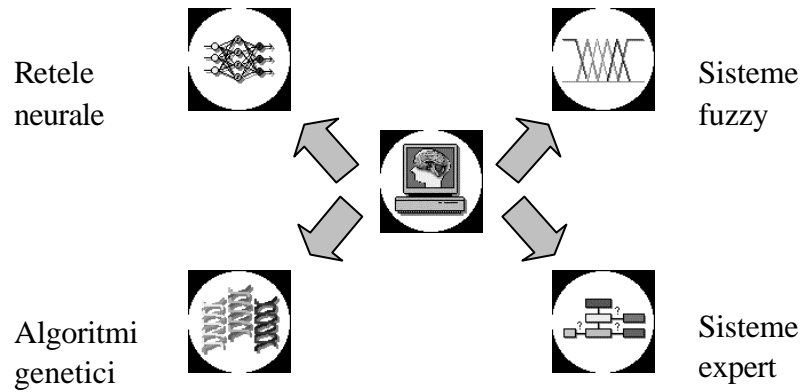


Fig. 1.4: Sisteme cognitive

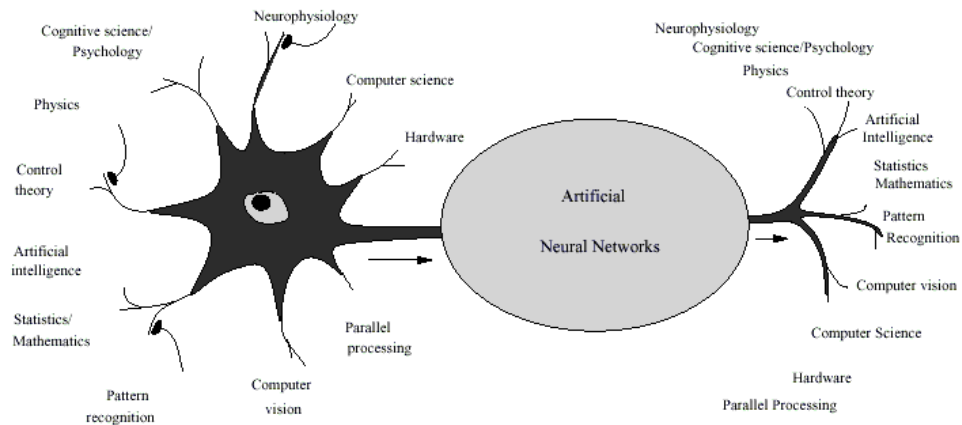


Fig. 1.5: Relatia dintre retelele neurale si alte domenii de cercetare

O analiza critica a teoriei retelelor neurale artificiale dezvoltata pâna în prezent ilustreaza câteva dezavantaje ale acestora, printre care:

- lipsa unei tratari teoretice unitare: de multe ori solutiile propuse se potrivesc numai aplicatiei concrete ilustrate, fiind dificila adaptarea comoda la o alta, diferita
- lipsa unor informatii referitoare la arhitectura necesara într-o aplicatie data, sub forma unor reguli de constructie clare (de exemplu, numar de straturi si numar de neuroni pe fiecare strat, retea cu reactie sau fara reactie)
- structuri de multe ori "stufosae", ridicând probleme deosebite în implementare, mai ales daca este necesara învatarea *on-line*. În plus, depanarea este practic imposibila, deoarece calculul este distribuit în toata masa retelei si nu este posibila localizarea "componentei" care conduce la functionare eronata la un moment dat. Totusi, acest aspect are si un efect binefacator, conferind retelei un grad sporit de robustete, în sensul ca defectarea unor "neuroni" nu conduce la degradarea dramatica a performantelor globale ale retelei.
- desi nu constituie neaparat un dezavantaj, unele retele neurale artificiale nu sunt plauzibile biologic, de exemplu cele care folosesc algoritmi de învatare supravegheata (care beneficiaza de existenta în fiecare moment a unui raspuns dorit). În plus, este posibil ca unele teorii bazate pe concepte aflate conjunctural "la moda" (holografia, sistemele haotice) sa nu se dovedeasca pâna la urma corecte în explicarea mecanismelor de functionare a creierului.

1.6 Note istorice

Preocupari privind studiul alcatuirii si functionarii creierului uman au aparut înca de la sfârșitul secolului trecut, remarcabile fiind rezultatele lui Ramón y Cajál (câștigător, alaturi de Camillo Golgi, al premiului Nobel pentru medicina în 1906) [153], creditat cu descoperirea retelei dense de interconexiuni din cortex. Epoca moderna este marcata de urmatoarele momente semnificative:

- **1943:** apare lucrarea "*A logical calculus of the ideas immanent in nervous activity*" a cercetatorilor americani McCulloch si Pitts, în care este introdus un model matematic pentru neuronul elementar. Desi caracterizat prin limitari majore, acest model permitea explicarea functionarii unor *ansambluri* de neuroni elementari.
- **1949:** cartea *The Organization of Behavior: A Neuropsychological Theory* a americanului D.O. Hebb prezinta modalitatea explicita de modificare a legaturilor dintre neuronii elementari, deschizând calea elaborarii unei game largi de algoritmi de învatare.

- **1958:** Rosenblatt introduce *perceptronul* ca model util în rezolvarea problemelor de clasificare și demonstrează o binecunoscută teoremă de convergență a algoritmului de adaptare corespunzător.
- **1969:** Minski și Papert demonstrează riguros în lucrarea *Perceptrons* ca arhitecturile cu un singur strat formate din neuroni elementari de tip perceptron au limitări majore. Lansarea ideii (dovedită mai târziu a fi false) că aceste limitări se "transferă" și la arhitecturile de tip multistrat avea să "înghețe" interesul cercetătorilor din acest domeniu pentru mai mult de un deceniu.
- **1982:** cercetătorul american J.J. Hopfield publică lucrarea "*Neural networks and physical systems with emergent collective computational abilities*" în care introduce un punct de vedere elegant asupra funcționării rețelelor neurale recurente cu conexiuni simetrice. Această lucrare și cele care vor apărea în anii imediat următori reprezintă în fapt momentul de reluare cu asiduitate a cercetării în acest domeniu.
- **1986:** Rumelhart, Hinton și Williams prezintă algoritmul de adaptare cunoscut sub numele *back-propagation* (cu propagarea inversă a erorii), utilizat pentru antrenarea rețelelor de tip perceptron multistrat. Acest algoritm, descris pentru prima dată de fapt în teza de doctorat a lui P.J. Werbos (1974), constituie și în prezent soluția cea mai des utilizată în aplicații dintre cele mai diverse.
- **1987:** se desfășoară la San Diego (SUA) prima conferință internațională consacrată rețelelor neurale artificiale. În următorii câțiva ani apar primele reviste specifice acestui domeniu (*IEEE Transactions on Neural Networks*, *Neural Networks*, *Neural Computation*), precum și unele organizații de profil (*International Neural Networks Society*, *Neural Networks Council* din cadrul *IEEE*).