

MACHINE LEARNING ÎN VIAȚA ZI DE ZI

Marin PEȘTEREAN^{1*},
Inga LISNIC^{2*},
Sergiu SCROB²

¹Universitatea Tehnică a Moldovei, Facultatea Calaculatoare Informatică și Microelectronică, Departamentul Informatică și Ingineria Sistemelor, grupa CR-191, Chișinău, Republica Moldova

²Universitatea Tehnică a Moldovei, Facultatea Calaculatoare Informatică și Microelectronică, Departamentul Ingineria Software și Automatică, Doctorandă, Chișinău, Republica Moldova

*Autorul corespondent: Peșterean Marin, e-mail: pesterean.marin@iis.utm.md

Rezumat. *Învățarea automată este o aplicație a inteligenței artificiale (AI) care oferă sistemelor capacitatea de a învăța și îmbunătăți automat din experiență, fără a fi programat explicit. Învățarea automată se concentrează pe dezvoltarea de programe de calculator care pot accesa date și să le utilizeze pentru a învăța singuri. Învățarea automată include patru tipuri de sarcini: învățarea supravegheată, învățarea nesupravegheată, învățarea semisupervizată, învățarea de consolidare. Învățarea automată are o aplicare vastă începând cu agricultura până la implimentarea ei intratarea tumorilor cerebrale.*

Cuvinte cheie: *Învățare automată, învățarea supravegheată, învățarea nesupravegheată, învățarea semisupervizată, învățarea de consolidare.*

Introducere

Inteligența artificială (AI) este o ramură largă a științei computerului, preocupată de construirea de mașini inteligente capabile să îndeplinească sarcini care necesită de obicei inteligență umană. AI este o știință interdisciplinară cu abordări multiple, dar progresele în învățarea automată și în învățarea profundă creează o schimbare de paradigmă în aproape toate sectoarele industriei tehnologice. Principalele subramuri ale AI sunt: învățare automată (ML) și Învatare profunda (DL)

Învățarea automată (ML) este studiul științific al algoritmilor și modelelor statistice pe care sistemele informatice le folosesc pentru a îndeplini o sarcină specifică, fără a utiliza instrucțiuni explicite, bazându-se în schimb pe tipare și inferență [1]. Este văzut ca un subset de inteligență artificială. Algoritmii de învățare automată construiesc un model matematic bazat pe date de probă, cunoscute sub numele de „date de instruire”, pentru a face predicții sau decizii fără a fi programat explicit pentru a îndeplini sarcina. Învățarea automată este strâns legată de statisticile de calcul, care se concentrează pe realizarea de predicții folosind calculatoare [2].

Sarcinile de învățare automată

În **învățarea supravegheată**, algoritmul construiește un model matematic dintr-un set de date care conține atât intrările, cât și rezultatele dorite [3]. Învățarea supravegheată este folosită în mod obișnuit în aplicații în care datele istorice prezic evenimente viitoare probabile. De exemplu, se poate anticipa momentul în care tranzacțiile cu cardul de credit pot fi frauduloase sau care clientul de asigurare este probabil să depună o cerere [2].

În **învățarea nesupravegheată**, algoritmul construiește un model matematic dintr-un set de date care conține doar intrări și fără etichete de ieșire dorite. Scopul este de a explora datele și de a găsi o structură în interior [2]. Învățarea nesupervizată funcționează bine la datele tranzacționale. De exemplu, poate identifica segmente de clienți cu atribute similare, care pot fi apoi tratate în mod similar în campaniile de marketing. Sau poate găsi principalele atribute care separă segmentele de clienți unul de celălalt.

Învățarea semisupervizată este utilizată pentru aceleași aplicații ca învățarea supravegheată. Dar folosește atât date pentru etichetare, cât și pentru cele fără etichetă - de obicei, o cantitate mică de date etichetate cu o cantitate mare de date fără marcă (deoarece datele fără etichetă sunt mai puțin costisitoare și depun eforturi mai mici pentru a le achiziționa). Acest tip de învățare poate fi utilizat cu metode precum clasificare, regresie și predicție [2].

Învățarea de consolidare este adesea folosită pentru robotică, jocuri și navigație. Odată cu învățarea de consolidare, algoritmul descoperă prin încercare și eroare care acțiuni dau cele mai mari recompense [3]. Acest tip de învățare are trei componente principale: agentul (elevul sau factorul de decizie), mediul (tot ceea ce interacționează agentul) și acțiuni (ceea ce poate face agentul). Obiectivul este ca agentul să aleagă acțiuni care să maximizeze recompensa așteptată într-un interval de timp dat. Agentul va atinge obiectivul mult mai repede urmând o politică bună. Efectuarea învățării automate presupune crearea unui model, care este instruit pe unele date de instruire și apoi poate prelucra date suplimentare pentru a face predicții. Pentru sistemele de învățare a mașinilor au fost utilizate și cercetate diferite tipuri de modele [2].

Folosirea în practică a tehnologiei Machine learning

Practica **agriculturii de precizie** a fost permisă de apariția GPS și GNSS. Capacitatea fermierului și a cercetătorului de a-și localiza poziția precisă într-un câmp permite crearea de hărți a variabilității spațiale a câtorva variabile care pot fi măsurate (de exemplu, randamentul culturii, caracteristicile terenului / topografia, conținutul de materie organică, nivelurile de umiditate, niveluri de azot, pH, EC, Mg, K și altele). Datele similare sunt colectate de sistemele de senzori montate pe recoltoare echipate cu GPS. Aceste tablouri constau în senzori în timp real care măsoară totul, de la nivelurile de clorofilă la starea apei din plante, împreună cu imagini multispectrale. Aceste date sunt utilizate împreună cu imagini prin satelit prin tehnologia cu rată variabilă (VRT), inclusiv semănătoare, pulverizatoare etc. pentru a distribui în mod optim resursele. Cu toate acestea, progresele tehnologice recente au permis utilizarea senzorilor în timp real direct în sol, care pot transmite fără fir date fără a fi necesară prezența umană [4].

„Agropiese TGR”, dealerul oficial Leica Geosystems, propune agricultorilor RM mai multe tipuri de sisteme de ghidare, în dependență de utilajul agricol și precizia necesară pentru prelucrarea terenurilor. Astfel pot fi procurate atât sisteme simple ca Leica mojoMINI2, cu precizie de 15-20 cm, cât și sisteme de înaltă precizie ca Leica mojo3D care poate fi dezvoltat pentru precizie ± 2 cm cu ajutorul receptorului Leica mojoXact plus, pentru controlul secțiilor agregatelor (semănători, stropitori) cât și pentru ghidarea automată a utilajelor agricole.

Utilajele echipate cu sistemele de ghidare au un avantaj mare pentru agricultura și sunt la îndemâna fermierului întregul an, astfel:

- toamna, ajută la pregătirea terenurilor pentru următorul sezon (pregătirea solului prin arat, pentru ca pulverizarea și fertilizarea să devină mai productivă);
- iarna, timp pentru analiza rezultatelor și luarea deciziilor pentru viitorul sezon, cu ajutorul hărților care conțin informații despre starea solului, recolta pe unitate de teren etc.
- primăvara, însămânțare, pulverizare și introducerea îngrășămintelor cu ajutorul mijloacelor de precizie, pentru un randament mai mare de producție;
- vara, recoltare eficientă, cu precizie maximă, zi și noapte.

Detectarea asistată de computer (CADE), numită și diagnostic asistat de computer (CADx), sunt sisteme care ajută medicii în interpretarea imaginilor medicale. Tehnicile de imagistică în radiografie, RMN și diagnosticare cu ultrasunete oferă o mulțime de informații pe care radiologul sau un alt profesionist medical trebuie să le analizeze și să le evalueze în mod scurt într-un timp scurt. Sistemele CAD procesează imagini digitale pentru apariții tipice și pentru a evidenția secțiuni vizibile, cum ar fi bolile posibile, pentru a oferi contribuții pentru a susține o decizie luată de profesionist [3].

O interfață creier-computer (BCI), uneori numită interfață de control neuronal (NCI), interfață minte-mașină (MMI), interfață neurală directă (DNI) sau interfață creier-mașină (IMC), este o cale de comunicare directă între un creier îmbunătățit sau cu fir și un dispozitiv extern. BCI

diferă de neuromodulare prin faptul că permite fluxul de informații bidirecționale. BCI sunt adesea direcționate către cercetarea, cartografierea, asistarea, creșterea sau repararea funcțiilor cognitive sau senzoriale-motorii umane

Neuralink-compania își propune să realizeze dispozitive pentru tratarea bolilor grave ale creierului pe termen scurt, cu scopul final de îmbunătățire umană, uneori numit transhumanism, Musk a definit dantela neurală ca un „strat digital deasupra cortexului” care nu ar presupune neapărat o inserție chirurgicală extinsă, dar în mod ideal un implant printr-o venă sau arteră. Musk a explicat că obiectivul pe termen lung este realizarea „simbiozei cu inteligența artificială” [3]. Nu există nici o îndoială că ML va avea un impact imens asupra planificării resurselor întreprinderii (ERP). Descoperirile din AI, ML vor convinge organizațiile să își optimizeze modelul de operare. În prezent, companiile încorporează instrumente ML pentru identificarea candidatului potrivit pentru recrutare. Aceste instrumente avansate îi ajută să eficientizeze operațiunile pentru a găsi cele mai bune talente, gestionând campanii de instruire și realizând planuri strategice de recrutare. Câteva companii IT folosesc ML pentru a verifica performanța candidatului efectuând o evaluare de codare online pe platforma lor, cum ar fi hackathons. Aici pot judeca potențialul candidaților examinând performanța lor generală. Acești algoritmi puternici iau această tehnologie la un nivel următor, oferind servicii valoroase precum analiza predictivă și recunoașterea modelului.

Concluzii

Învățarea automată este în creștere rapidă în domeniul informaticii. Are aplicații în aproape toate celelalte domenii de studiu și este deja pus în aplicare comercial, deoarece învățarea automată poate rezolva probleme prea dificile sau consumatoare de timp pentru om. Utilizarea învățării automate în viața de zi cu zi oferă mai multe oportunități utilizatorului ca: o precizie deosebit de mare, economie în timp, rezolvarea de probleme dificile, acces la servicii de calitate înaltă în orice domeniu.

Referințe

1. SHAI SHALEV-SHWARTZ and SHAI BEN-DAVID, *Understanding Machine Learning: From Theory to Algorithms*, 2014
2. OLIVER TEOBALD, *Machine Learning for Absolute Beginners*, 2017
3. MITCHELL, T, *Machine Learning*, 1997.
4. RADU V, Oportunități de utilizare a agriculturii de precizie în Republica Moldova, [online]. 2017, pp. 1-37. [accesat 12.02.2020]. Disponibil: <http://tinread.usarb.md:8888/tinread/fulltext/radu/opportunitati.pdf>