

Tehnici bazate pe algoritmi inteligenți folosiți în prevenția cancerului de piele

Ioana PETCU^{1,2}, Dragoș-Cătălin BARBU^{1,4}, Silviu-Ioan NEGOIȚĂ^{2,3}

¹ Institutul Național de Cercetare-Dezvoltare în Informatică - ICI București

² Universitatea de Medicină și Farmacie „Carol Davila” - București

³ Spitalul Universitar de Urgență Elias, București

⁴ Academia de Studii Economice din București

ioana.petcu@ici.ro, dragos.barbu@ici.ro, silviusneg@gmail.com

Rezumat: Articolul prezintă o analiză a instrumentelor de inteligență artificială bazată pe algoritmi de învățare automată ce pot fi folosite în predicția și prevenția cancerului de piele, în special pentru cea mai agresivă formă, respectiv melanomul cutanat. Tehnici precum Machine Learning (ML) și Deep Learning (DL) bazate pe algoritmi inteligenți sunt folosite tot mai mult în dezvoltarea sistemelor de asistare medicală cu ajutorul cărora se propune, pe baza unui set de analize, un diagnostic pentru un pacient. Astfel, în cazul diagnosticului pentru cancerul de piele cu ajutorul sistemelor bazate pe inteligență artificială, rolul medicului este de a verifica și valida diagnosticul propus de mașina inteligentă, de a-l folosi în sprijinul luării deciziei medicale corecte de diagnostic, tratament și prevenție. Concluziile acestui articol reliefează rolul inteligenței artificiale și a sistemelor de asistare a medicilor, folosind tehnici ce permit computerelor de înaltă performanță învățarea automată, bazându-se pe date și statistici, pentru ameliorarea prevenției primare și pentru detectarea precoce a unei patologii frecvente și severe cum este cancerul de piele.

Cuvinte cheie: machine learning, inteligență artificială, cancer de piele, melanom cutanat, boli dermatologice, data mining, data analytics, diagnostic, recunoașterea modelelor, detectarea anomaliilor.

Techniques based on intelligent algorithms used in the prevention of skin cancer

Abstract: The article presents an analysis of artificial intelligence tools based on machine learning algorithms used for the prediction and prevention of skin cancer, especially for its most aggressive form-cutaneous melanoma. Techniques such as machine learning and deep learning based on intelligent algorithms are increasingly used in the development of supportive tool for diagnosis based on a set of tests. Thus, in the case of skin cancer diagnosis assisted by systems based on artificial intelligence, the role of the physician is to verify and validate the diagnosis proposed by the intelligent machine, and to use it as support to take the correct medical decision for diagnosis, treatment and prevention. The findings of this article highlight the role of artificial intelligence and of physician-support systems using techniques that enable high-performance computers to learn automatically based on data and statistics, to improve the primary prevention and early detection of skin cancer, which is a frequent and aggressive pathology.

Keywords: machine learning, artificial intelligence, skin cancer, melanoma, dermatologic diseases, data mining, data analytics, diagnosis, pattern recognition, anomaly detection.

1. Introducere

1.1. Contextul global al incidenței cancerului și al acțiunilor de prevenție

La nivel global cancerul este o problemă majoră de sănătate, reprezentând în Europa a doua cauză de deces. Povara acestei boli este foarte greu de suportat și în continuă creștere. Ultimul raport al Parlamentului European publicat în 2022 (Parlamentul European, 2022) privind situația cancerului în Europa ne arată că 1,3 milioane de persoane mor anual din cauza cancerului, iar în Europa se înregistrează un sfert din cazurile diagnosticate cu această boală la nivel mondial, deși deține mai puțin de 10% din populația lumii. La nivel global, cancerul cauzează anual aproape 10 milioane de decese conform site-ului oficial al Organizației Mondiale a Sănătății (World Health Organization, 2022). Previziunile nu sunt deloc încurajatoare, estimându-se că până în 2035 numărul bolnavilor de cancer din Uniunea Europeană (UE) va crește cu 24% dintr-o populație totală a Europei de 748 milioane, devenind astfel principala cauză de deces.

În acest context, la nivelul Uniunii Europene, prevenirea cancerului are un rol major, acordându-le prioritate strategiilor cu impact semnificativ în reducerea celor mai mulți factori de risc pentru cancer, precum factorii de mediu (poluarea aerului, expunerea la substanțele chimice carcinogene, arderea combustibililor în interior și radiațiile) sau factorii sociali (sărăcie, nivel precar de educație, acces restrâns la sistemul de sănătate). Astfel, la nivelul Uniunii Europene a fost lansat Planul European de Luptă împotriva Cancerului care își propune patru direcții majore de acțiune în vederea creșterii ratei de supraviețuire, și anume:

- *Prevenție susținută și consecventă.* Se cunoaște faptul că aproximativ 40% din cazurile de cancer din UE pot fi prevenite, prin: combaterea fumatului, reducerea consumului de alcool, reducerea poluării mediului, reducerea expunerii la substanțe carcinogene și la radiații, precum și îmbunătățirea cunoștințelor și a educației în domeniul sănătății pentru a promova un stil de viață sănătos.
- *Îmbunătățirea depistării precoce* a cancerului prin diagnosticarea bolii în stadii incipiente cu ajutorul screening-ului, poate salva vieți.
- *Accesul egal la diagnostic și tratament* prin îmbunătățirea accesului la servicii de calitate și siguranță pentru toți cetățenii.
- *Îmbunătățirea calității vieții bolnavilor de cancer* și a supraviețuitorilor prin acces egal la îngrijiri corespunzătoare post-tratament, la protecție socială și la servicii de asigurări.

Planul European de Luptă împotriva Cancerului abordează atât factorii-cheie de risc, cât și factorii sociali determinanți ai cancerului. Ultimii ani au evidențiat progrese notabile în domeniul prevenției, diagnosticului și tratamentului cancerului, ceea ce la nivelul Uniunii Europene a însemnat un număr de peste 12 milioane de supraviețuitori ai bolii, dintre care 300.000 au fost copii.

Prevenția joacă un rol esențial în lupta împotriva cancerului, fiind considerată cea mai eficientă metodă de control al cancerului și sustenabilă pe termen lung. Prin adoptarea celor 12 măsuri ale Codului European de Luptă Contra Cancerului, fiecare cetățean își poate reduce riscul individual de boală, iar la nivel de populație peste 40% din cancere pot fi evitate (Parlamentul European, 2022).

1.2. Cancerul de piele și tipurile sale

Dintre toate tipurile de cancer cel mai frecvent este cancerul de piele, formele sale diverse reprezentând, în ansamblu, circa 33% din totalul cancerelor diagnosticate, cu o creștere de patru ori mai mare în ultimul deceniu, atât în Europa cât și în America (World Health Organization, 2022). Pielea este cel mai mare organ al corpului, iar cancerul de piele este cel mai frecvent tip de cancer la populația caucaziană, având cauză principală expunerea excesivă la soare.

Principalele tipuri de cancer de piele sunt: carcinomul bazocelular, carcinomul spinocelular și melanomul. La nivel mondial se estimează că apar anual 2-3 milioane de cazuri noi de carcinoame ale pielii și peste 130.000 de cazuri de melanom (World Health Organization, 2022). Considerat cel mai periculos tip de cancer de piele, melanomul este responsabil de 75% dintre decesele cauzate de cancerul de piele, deși, conform statisticilor Societății Americane de Cancer, cazurile de melanom reprezintă sub 5% din totalul cazurilor de cancer de piele. Este însă cel mai frecvent cancer la tinerii între 25 și 29 de ani. Melanomul ia naștere prin transformarea malignă a celulelor normale ale pielii numite melanocite, care produc pigmentul brun melanină cu rol în protejarea pielii față de radiația solară. Melanocitele transformate malign încep să se înmulțească fără control, creând o tumoră, de obicei pe zonele pielii expuse la soare. Descoperit la începutul evoluției, melanomul poate fi vindecat complet prin excizie chirurgicală. Dacă este lăsat să evolueze, celulele sale se pot răspândi în restul corpului, producând noi tumori și, într-un final, producând decesul pacientului.

Majoritatea cazurilor de cancer de piele se află în categoria non-melanom: carcinomul bazocelular (BCC), carcinomul cu celule scuamoase (SCC) formate din celulele straturilor bazal și, respectiv, superioare ale epidermului. Aceste tumori au o evoluție lentă și o mortalitate redusă, celulele lor canceroase având o tendință scăzută de a se răspândi și în alte părți ale corpului.

Afectează predominant persoanele în vârstă cu istoric de expunere excesivă la soare. Cancerele non-melanom sunt mai ușor de tratat în comparație cu melanomul și se rezolvă chirurgical în majoritatea cazurilor. Fazele avansate pun însă probleme de tratament, iar prin frecvența lor cauzează costuri materiale, umane și sociale importante.

În acest context, pentru reducerea mortalității, morbidității și a costurilor medicale și sociale cauzate de cancerul de piele, sunt esențiale **prevenția și diagnosticarea precoce**.

Articolul acesta își propune să prezinte tehnici bazate pe algoritmi inteligenți folosite pentru prevenția cancerului de piele, atât prevenția primară care urmărește să împiedice apariția cancerului, cât și cea secundară care presupune depistarea cât mai precoce a unui cancer deja apărut. Studiile au demonstrat că, în cazul melanomului, dacă este descoperit și tratat în fazele de început, rata de supraviețuire după 5 ani este de 95%, iar în caz contrar, descoperit după metastazare, rata de supraviețuire scade la 15%. Acest lucru a impulsionat cercetarea, în special în zona de tehnologie în domeniul inteligenței artificiale, să găsească mecanisme și algoritmi inteligenți de depistare timpurie a cancerului de piele prin metode precum Machine Learning sau Deep Learning. Diagnosticarea precoce are un rol vital în determinarea bolii și în vindecarea pacientului, detectarea melanomului asistată de computer fiind de un real ajutor.

2. Tehnici de inteligență artificială folosite în prevenția cancerului de piele

Aflată din ce în ce mai mult în centrul atenției cercetărilor științifice, Inteligența Artificială (IA) a devenit tot mai prezentă în practica medicală, fiind considerată o componentă esențială pentru viitorul serviciilor medicale, datorită abilităților sale de rezolvare a problemelor, de luare a deciziilor și de recunoaștere a modelelor, beneficiile ei neîncetând să ne uimească.

Inteligența Artificială este domeniul informaticii care se ocupă cu transmiterea abilității decisive și a capacității de gândire a mașinilor, îmbinând astfel cunoștințe de informatică, analiză a datelor și matematică pură.

Tehnici de IA sunt folosite în prevenția bolilor cu scopul de a oferi date și informații personalului medical despre pacienți referitor la predicții, diagnostice, tratamente și servicii medicale inteligente.

Specific inteligenței artificiale este modul în care calculatoarele, având o cantitate suficientă de informații, funcționează și acționează identic oamenilor, dar cu o viteză mult mai mare de procesare atunci când vine vorba de abilități de calcul și analiză. Ingineria cunoașterii joacă un rol important în relația dintre obiecte și proprietăți. De asemenea, există situații când computerul poate lua o decizie. În această situație se folosesc algoritmi inteligenți cu ajutorul cărora calculatorul este capabil să găsească modele pentru a lua o decizie. Este de remarcat rolul pe care îl au algoritmi de inteligență artificială în găsirea de modele specifice în practica medicală.

Un aspect important de remarcat în studierea și înțelegerea modului cum Inteligența Artificială a fost dezvoltată în timp, încă din 1942 când I. Asimov pomenea în cartea sa *“Runaround”* (Asimov, 1942) de un pachet ce conținea trei legi esențiale, cărora IA i se supune și care presupune următoarele:

- Un robot nu are voie să facă rău unei ființe umane sau, prin lipsa de intervenție, să permită ca unei ființe umane să i se facă un rău.
- Un robot trebuie să respecte ordinele date de o ființă umană, atâta timp cât ele nu contravin primei reguli.
- Un robot trebuie să-și protejeze propria existență, atâta timp cât aceasta nu contravine primelor două legi.

Mai există și o lege de nivel zero, aceasta fiind considerată ca lege supremă, care le modifică pe toate celelalte, astfel:

- Un robot nu are voie să facă rău umanității sau să permită, prin neintervenția lui, ca umanitatea să fie pusă în pericol.

În anul 2017, la nivelul Uniunii Europene, printr-o Rezoluție a Parlamentului European, au fost inițiate o serie de recomandări privind normele de drept civil în ceea ce privește robotica, adoptându-se Codul Civil de Reguli în Robotică (Official Journal of the European Union, 2017).

Observăm o similitudine între legile inteligenței artificiale și jurământul lui Hipocrate, adoptat în varianta modernă în anul 1975 de către Asociația Medicală Mondială în cadrul Declarației de la Geneva, și care, în esență, afirmă că actul medical și profesia de medic sunt exercitate în slujba umanității, sănătatea pacienților fiind o obligație sacră, fără deosebire de naționalitate, rasă, religie, iar cunoștințele medicale nu vor fi folosite contrar legilor umanității.

Cele două idei principale pe care se bazează IA sunt:

- studierea proceselor de gândire ale ființei umane;
- reprezentarea acestor procese prin intermediul mașinilor (computere, roboți).

În esență, este vorba de inteligența de care dau dovadă roboții, echivalentul inteligenței naturale în domeniul informaticii. Andreas Kaplan și Michael Haenlein au descris-o ca fiind „capacitatea unui sistem de a interpreta corect datele externe, de a învăța din ele și de a folosi tot ce a învățat pentru a-și atinge obiectivele și sarcinile, printr-o abordare flexibilă”.

Cele mai importante tehnici de Inteligență Artificială sunt:

- *învățarea automată (ML)*, parte integrantă a inteligenței artificiale care se ocupă cu procesul de învățare al datelor de intrare și *învățarea profundă (DL)*, detaliate în paragraful 2.1;
- *tehnica de procesare a limbajului natural (NLP)* reprezintă interacțiunea dintre computere și limbajul uman în care computerele sunt programate să proceseze limbaje naturale. Natura limbilor umane face ca procesarea limbajului natural să fie dificilă din cauza regulilor care sunt implicate în transmiterea informațiilor folosind acest limbaj și nu sunt ușor de înțeles de către computere. NLP folosește algoritmi pentru a recunoaște și a abstractiza regulile limbajelor naturale în care datele nestructurate din limbajele umane pot fi convertite într-un format care este înțeles de computer;
- *automatizare și robotică*, cu ajutorul cărora se realizează sarcini monotone și repetitive de către mașini. Multe organizații folosesc învățarea automată, rețelele neuronale și graficele în automatizare. O astfel de automatizare poate preveni problemele de fraudă online, folosind tehnologia CAPTCHA. Automatizarea proceselor robotizate este programată pentru a efectua sarcini repetitive de mare volum, care se pot adapta schimbării în diferite circumstanțe;
- *viziunea artificială*, specifică prin aparatele ce pot captura informații vizuale cu ajutorul camerelor și apoi le pot analiza. Conversia analog-digitală este folosită pentru a converti imaginea în date digitale, iar procesarea semnalului digital este folosită pentru a procesa datele, pentru ca apoi datele rezultate să fie transmise către calculator. Întâlnim două aspecte importante: *sensibilitatea*, care este capacitatea mașinii de a percepe impulsuri slabe și *rezoluția*, intervalul până la care mașina poate distinge obiectele. Poate fi folosită în identificarea semnăturii, recunoașterea modelelor și analiza imaginilor medicale.

Studiile au demonstrat deja utilizarea cu succes a învățării automate în clasificarea și diagnosticarea cancerului de piele (Andre et al.; 2017, Das et al., 2021), pe baza imaginilor digitale, la un nivel de performanță egal sau superior dermatologilor certificați, cel puțin în contextul experimental.

Într-o eră a medicinei personalizate, există un impuls către o abordare bazată pe date care să permită predicția precisă a rezultatelor clinice pe termen lung pentru pacienții individuali.

Tehnicile de învățare automată sunt foarte bune în gestionarea cantităților mari de date la un nivel ridicat din bazele de date ale pacienților, cum ar fi, de exemplu, fișele medicale electronice, și sunt capabile să detecteze modele sofisticate de covariație sau corelație a datelor pe care metodele statistice tradiționale nu le pot descoperi. Aceste abordări au fost utilizate cu un succes din ce în ce

mai mare pentru a prezice evoluția bolii și prognosticul dat pacienților în multe domenii ale medicinei, precum riscul de readmisie după externarea din spital și progresia cancerului.

2.1. Machine Learning

Învățarea automată, un subset al inteligenței artificiale, se concentrează asupra capacității computerelor de a primi date și de a învăța singure, manipulând algoritmi pe măsură ce organizează informațiile pe care le procesează.

Obiectivul învățării automate (Machine Learning) îl reprezintă dezvoltarea de tehnici ce permit computerelor să învețe și să se îmbunătățească în mod automat. Învățarea automată implică modele statistice și algoritmi care pot învăța progresiv din date pentru a prezice un anumit tipar comportamental.

Vârful de lance în adoptarea inteligenței artificiale în medicină îl reprezintă radiologia, care folosește algoritmi bazați pe imagini pentru a clasifica fenotipurile tumorale și a prezice proprietățile genetice. Odată cu răspândirea continuă și utilizarea tehnologiilor emergente, IA este din ce în ce mai studiată în depistarea cancerului de piele. Utilizarea rețelelor neuronale poate fi folosită la dezvoltarea unui sistem de evaluare a imaginilor pielii pentru a diagnostica cancerul de piele.

Utilizarea tehnicilor de inteligență artificială în detectarea timpurie a cancerului de piele folosind datele medicale ale pacienților anteriori, presupune ca algoritmul de antrenament să folosească parametrii de intrare precum dimensiune, culoare, textură, perimetru, iar ca parametru de ieșire obținem probabilitatea ca tumora să fie malignă sau nu.

Detectarea precoce a cancerului de piele este esențială pentru un tratament eficient și pentru rezultate mai bune. Specialiștii pot diagnostica cu exactitate semnalmentele cancerului, dar având în vedere numărul limitat al specialiștilor din domeniul dermatologiei, în special în anumite zone geografice, combinat cu creșterea accelerată a numărului pacienților cu aceste tumori la nivel global, este util să se dezvolte sisteme automatizate care pot ajuta diagnosticarea bolii în mod eficient, pentru a salva vieți și pentru a reduce sarcina financiară asupra pacienților și a societății.

Învățarea, fie ea de tip automat „Machine Learning” sau de tip profund „Deep Learning”, reprezintă încercarea de a găsi un tipar, spre deosebire de Inteligența Artificială care folosește propria experiență pentru a acumula cunoaștere și a o aplica în medii noi, pentru rezultate mai bune.

În comparație cu metodele statistice tradiționale, care se concentrează pe inferență, metodologia ML se concentrează mai mult pe predicție. Aceasta înseamnă că metodele ML urmăresc mai degrabă să anticipeze comportamentul viitor, decât să creeze asocieri între date.

Învățarea automată este, de asemenea, deosebit de utilă atunci când se analizează seturi de date complexe și detaliate cu un număr mare de variabile de intrare. Astfel, un eșantion mai mare permite algoritmilor ML să facă asocieri mai bune în cadrul datelor și, astfel, să genereze rezultate mai precise. Comparativ, metodele statistice tradiționale au fost concepute pentru a fi cele mai precise și de succes cu un număr mic până la moderat de variabile de intrare. Pe măsură ce numărul de intrări crește, modelele statistice tind să devină mai puțin precise.

Deși există multe beneficii ale implementării ML în dermatologia clinică, este esențial să se discute și posibilele limitări ale implementării acesteia. O astfel de limitare a implementării o reprezintă cantitatea de date necesară pentru operarea algoritmilor ML. Există registre mari de pacienți cu boli dermatologice, astfel că va trebui să existe o colaborare semnificativ mai mare la nivel național și internațional pentru a se asigura că există o acoperire cuprinzătoare a datelor la pacienții cu boli de piele. O altă limitare a implementării ML este lipsa capacității operatorului uman de a explica modul în care funcționează algoritmi de învățare automată. Deși există metode de evaluare a performanței unui algoritm, nu există nicio modalitate de a-și explica decizia în mod rațional. Ca atare, ele sunt adesea numite tehnologii de tip „cutie neagră” (Black box), caz în care, este important ca interpretarea rezultatelor ML să fie făcută de un clinician experimentat.

2.2. Deep Learning

Deep Learning (învățarea profundă) este un subset al învățării automate, bazat pe rețele neuronale artificiale pentru *analiza predictivă*. Învățarea profundă este capabilă să implementeze o funcție care este utilizată pentru a imita funcționalitatea creierului prin crearea de modele și procesarea datelor. Deep Learning, bazată pe un set de algoritmi care încearcă să modeleze abstractizările de date la un nivel ridicat, este utilizat pentru luarea deciziilor în domenii precum mașinile fără șofer, recunoașterea vorbirii, analiza imaginilor, identificarea cancerului în sânge și a tumorilor.

În general, executăm tot timpul două sarcini în mod conștient sau subconștient și anume: de a împărți pe categorii și de a face predicții pentru mai multe evenimente viitoare pe baza datelor anterioare.

În cazul analizei tipurilor de algoritmi inteligenți folosiți pentru prevenția cancerului de piele regăsim:

- **Categorizarea.** Clasificarea unei leziuni în una din cele două categorii- cancer de piele sau leziune necanceroasă în funcție de formă, mărime, culoare, aspect, identificate de obicei pe baza unei imagini digitale. Odată ce leziunea poate fi corect clasificată pe baza unui anumit set de caracteristici, algoritmul este capabil să clasifice orice leziune nouă, pe baza identificării respectivului set de caracteristici.
- **Predicția.** În cazul previziunii liniare vom fi capabili să prezicem unde este cel mai probabil să se situeze celulele, iar în cazul previziunii sub formă de curbă, avem o predicție a potrivirii noilor celule în intervalul de puncte de date existente.




Figura 1. Categorizarea și predicția pentru leziunile maligne
(Sursă: cercetare proprie)

Așa cum se vede și în Figura 1, categorizarea celulelor, cât și predicția se încheie într-un punct similar. Dacă putem să antrenăm modelul computerizat să deseneze linia curbă pe baza punctelor de date cu care am lucrat, atunci putem extinde acest lucru pentru a se aplica în diferite modele, cum ar fi desenarea unei linii curbe în planuri tridimensionale. Acest lucru poate fi realizat prin antrenarea unui model cu o cantitate mare de date etichetate și neetichetate, care se numește învățare profundă.

Din punct de vedere al arhitecturii Deep Learning întâlnim trei tipuri (Barbu, 2019):

- *perceptron multistrat* (MLPs) este alcătuit dintr-un strat de intrare, un strat de ieșire și unul sau mai multe straturi ascunse. Denumirea de arhitectură profundă se referă la adâncimea rețelei datorată straturilor ascunse (vezi Figura 2). Fiecare muchie corespunde unui parametru de pondere care va trebui să urmeze un proces de învățare.




Figura 2. Perceptron multistrat
(Sursă: adaptare după (Rosenblatt, 1986))

- rețele neuronale convoluționale (CNN)* - tip de ML care simulează procesarea neuronilor biologici, rețele de ultimă generație folosite la recunoașterea modelelor în analiza imaginilor medicale. Figura 3 prezintă o simplă detecție a cancerului de piele folosind CNN obișnuit. Stratul de convoluție evaluează rezultatul neuronilor care sunt conectați la zona locală de intrare, calculul realizându-se prin înmulțirea punctului între greutatea fiecărui neuron și zonă. Principalul scop al stratului de pooling este de a subeșantiona imaginea de intrare pentru a reduce sarcina de calcul, memoria și numărul de parametri (suprafitting). Reducerea dimensiunii imaginii de intrare face ca rețeaua neuronală să fie sensibil mai mică la deplasarea imaginii (independent de poziție).




Figura 3. Detecție simplă a cancerului de piele folosind CNN
(Sursă: Zhang et al., 2019)

- rețele neuronale recurente (RNNs)* – au capacitatea de a optimiza caracteristicile oferind rezultate de clasificare mai bune. Figura 4 prezintă un exemplu de recunoaștere a caracteristicilor vizuale folosind RNN și clasificatorul liniar softmax pentru a diferenția leziunile cutanate pigmentate (PSL) ale nervului și melanomului malign atunci când sunt diagnosticate prin dermatoscopie.

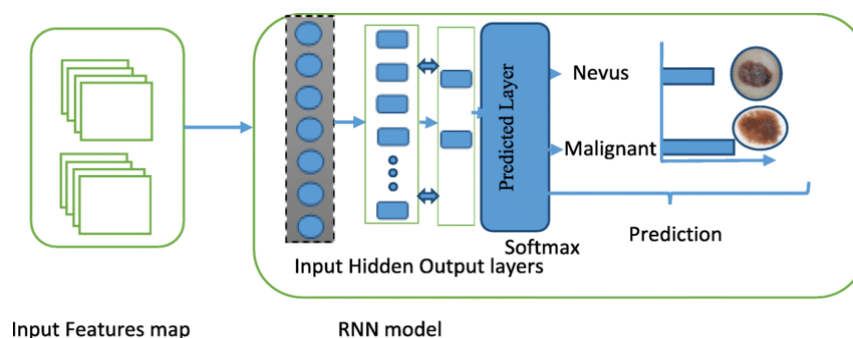


Figura 4. Recunoașterea caracteristicilor vizuale folosind RNN
(Sursă: Abbas & Celebi, 2019)

3. Algoritmi inteligenți folosiți în prevenția cancerului de piele

Analiza parametrilor folosind algoritmi de tip Machine Learning se face pe datele pacienților în vederea unor evaluări predictive și stabilirea unor diagnoze.

Algoritmii de IA sunt formați din algoritmi de învățare automată și algoritmi de învățare profundă, reprezentați și în Figura 5.

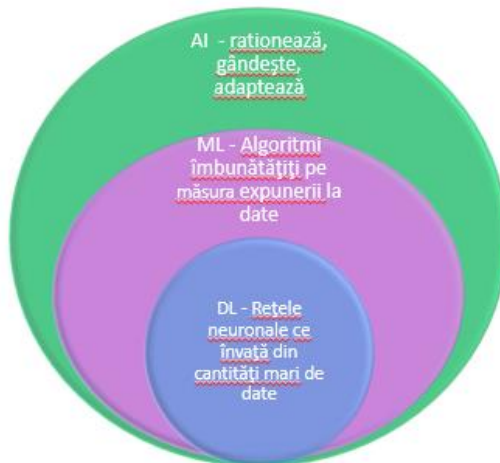



Figura 5. Algoritmi de inteligență artificială, învățare automată și învățare profundă (Sursă: cercetare proprie)

Scopul principal al algoritmilor inteligenți este de a permite computerelor să învețe singure și să ia o decizie sau să găsească modele utile. În Figura 6 sunt prezentate comparativ cele două modalități după care funcționează algoritmii logici și algoritmii bazați pe învățare automată.



Figură 6. Algoritm logic vs. Algoritm Machine Learning (Sursă: cercetare proprie)

În cazul algoritmului bazat pe logică, fluxul este bine definit și cunoscut în prealabil. Există mai multe scenarii din viața reală în care logica nu poate fi definită. În astfel de cazuri, învățarea automată s-a dovedit a fi extrem de utilă.

3.1. Tipuri de algoritmi inteligenți

Tehnicile de învățare automată preiau parametrii de intrare și datele de ieșire de referință așteptate și generează o logică care este apoi implementată în producție.

Există diferiți algoritmi de învățare automată:

- *algoritmi de învățare nesupravegheată*, sunt cei în care nu se folosesc informații clasificate pentru a acționa asupra lor fără nicio îndrumare;
- *algoritmi de învățare supravegheată*, sunt cei prin care se deduce un model din datele de antrenament, care constă dintr-un set de date de intrare și rezultatul dorit;
- *algoritmi de învățare prin consolidare* sunt cei care învață să efectueze o acțiune din

experiență prin încercări și erori, și aleg care acțiune aduce cele mai mari recompense într-o anumită perioadă de timp.

În funcție de problemele pe care oamenii le întâmpină și le rezolvă, există trei categorii în care acești algoritmi pot fi împărțiți pentru a efectua aceleași acțiuni:

- **Clasificarea.** Oamenii iau decizii bazate pe clasificare. Minteă umană va procesa un algoritm cu experiență anterioară (date), iar apoi rezultatul va fi afirmativ sau negativ. În același mod, acești algoritmi de clasificare vor prelua unele date de intrare, și pe baza acestora va prezice afirmativ sau negativ. Dintre acești algoritmi regăsim: Naive Bayes, Regresia logistică, SVM.
- **Regresia.** Rezultatul este continuu, nu există o categorie anume. De exemplu: Care va fi temperatura mâine? Minteă umană se va gândi la anotimp și la temperatura zilelor anterioare și va prezice un număr. Printre acești tipuri de algoritmi regăsim: regresia liniară, gradient boosting, random forest.
- **Clusterizarea.** Uneori nu trebuie să luăm o decizie cu privire la datele de intrare, ci să le distingem pe cele ciudate. De exemplu, segregarea diferitelor formațiuni cancerigene de cele necancerigene și a găsi un anumit tip de modele. Ca algoritmi de clusterizare avem: K-means clustering și clusterizare ierarhică.

Cele patru metode de clusterizare întâlnite în învățarea automată sunt:

- **Ierarhică.** Aceasta definește un mod de lucru și este o metodă ce formează un cluster în mod ierarhic. Noul cluster este format folosind o structură formată anterior.
- **Bazată pe densitate.** În această metodă, o regiune densă este considerată un cluster care are unele asemănări. Este diferită de regiunea densă inferioară a spațiului obiect. DBSCAN este cunoscut drept clustering spațial bazat pe densitatea aplicațiilor cu zgomot.
- **Partiționarea.** Când există un set de date de N număr de obiecte, această metodă construiește „ K ”, ca partiție a datelor. Această partiție este clusterul, adică construcția K , partiția ($K \leq N$). Cerințele care trebuie îndeplinite: fiecare grup sau set de date trebuie să conțină cel puțin un obiect și fiecare obiect ar trebui să aparțină unui singur grup. Unul dintre exemplele de partiționare este gruparea K-means.
- **Bazat pe grilă.** Spațiul obiect reprezentând un număr finit de celule, formează o structură grilă. Această metodă oferă o procesare rapidă a clusterului.

3.2. Tehnici care folosesc algoritmi inteligenți în prevenția riscului de apariție a cancerului de piele

Tipurile de tehnici care folosesc Inteligența Artificială în detectarea și clasificarea cancerului de piele, pot fi structurate în *tehnici superficiale* și *tehnici profunde*.

Tehnicile superficiale folosesc fie algoritmi simpli de învățare automată, cum ar fi o mașină vectorială suport (SVM), fie doar câteva straturi de rețele neuronale (Goodfellow, Bengio & Courville, 2016).

Dacă, arhitectura IA este o rețea neuronală care constă din cel puțin trei straturi, aceasta este clasificată ca o *tehnică profundă* (Mustafa, Dauda & Dauda, 2017).

Conform (Takiddin et al., 2021) majoritatea studiilor care au folosit tehnici superficiale au adoptat un SVM (64,3%), care este un clasificator comun de două clase și care utilizează un hiperplan ca limită de decizie (Marsland, 2011). Restul studiilor (35,7%) au adoptat *algoritmul naive Bayes* (NB; 7,1%), care este un clasificator probabilistic ce presupune independență condiționată între caracteristici (Marsland, 2011); *regresie logistică* (LR; 7,1%), care utilizează probabilitatea pentru predicție; *k- cei mai apropiați vecini* (kNNs; 7,1%), care clasifică un eșantion pe baza

eșantioanelor apropiate acestuia; și *random forest* (RF; 7,1%), care clasifică folosind arbori de decizie. Un model hibrid (7,1%) a clasificat imaginile prin mai multe iterații folosind Adaboost și un SVM.

În cazul studiilor (Du, Emam & Gniadecki, 2020) care au folosit tehnici profunde, majoritatea au adoptat diferite tipuri de *rețele neuronale convoluționale* (CNN; 92,3%), care acordă importanță părților imaginilor folosind arhitecturi pre-antrenate ImageNet (46,2%), inclusiv rețeaua reziduală (ResNet), Inception, AlexNet, MobileNet, Visual Geometry Group (VGG), Xception, DenseNet și GoogleNet. În plus, unele dintre studiile bazate pe CNN (28,2%) au creat CNN-uri sau ResNet-uri personalizate. Altele au adoptat diferite combinații de CNN-uri împreună cu alte modele hibride (12,8%), precum și utilizarea modelelor de ansamblu (10,3%); restul studiului (2,6%) folosind biblioteca OpenCV.

Numeroase studii au implementat învățarea automată în aria de diagnostică a cancerului de piele. Comparativ cu acestea, cercetările cu privire la utilizarea învățării automate în cazul predicției riscului de a dezvolta cancer de piele au fost mult mai puține.

Remarcăm două studii de investigare a riscului de a dezvolta cancer de piele non-melanom (Wang et al., 2019) și (Roffman et al., 2018). Aceștia au folosit rețele neuronale convoluționale (CNN) și, respectiv, rețele neuronale artificiale (ANN), pentru a delimita riscul de a dezvolta cancer de piele non-melanom. Ambele abordări sunt ramuri ale învățării profunde și folosesc capacitatea algoritmului de a extrage informații importante de clasificare din fiecare nod al unei rețele de date. Ambele studii au inclus date de la pacienții cu cancer de piele non-melanom, precum și o abundență de date de la pacienții non-cancer. Sistemul lui (Wang et al., 2019) a analizat date de la un total de 9.494 de pacienți, folosind 20 de caracteristici relevante clinic per pacient și au raportat rezultate mai mari (ASC 0,89, sensibilitate 83,1%, specificitate 82,3%) decât (Roffman et al., 2018), care au analizat datele de la un total de 462.630 de pacienți, folosind 13 caracteristici relevante clinic per pacient (ASC 0,81, sensibilitate 86,2%, specificitate 62,7%).

4. Concluzii

Incidența cancerului și povara societății (Parlamentul European, 2022) sunt de așteptat să crească în continuare. Dincolo de terapie, reducerea substanțială a mortalității provocate de cancer necesită o înțelegere îmbunătățită a riscului acestei boli. Implementarea unor strategii eficiente de intervenție preventivă și depistarea precoce a cancerelor cu ajutorul Inteligenței Artificiale și a Machine Learning ar putea progresa pentru a evita problema privind diagnosticarea, aceste provocări substanțiale putând fi depășite. O astfel de abordare ar ajuta medicii să selecteze cele mai bune metode de tratament, să economisească timp pentru pacienți, să reducă costurile de tratament și să îmbunătățească calitatea tratamentului în general, prin reducerea numărului de încercări și erori în procesul de tratament.

Cel mai eficient mod, decât orice tratament și cea mai rentabilă strategie pe termen lung de control al cancerului, este prevenția. Identificarea persoanelor cu risc crescut de a dezvolta un anumit tip de cancer ar permite implementarea unei game de intervenții preventive, precum modificarea și adoptarea unui stil de viață sănătos și depistarea precoce a anumitor cancere la persoanele cu risc crescut de a face boala.

Acest articol evidențiază importanța utilizării tehnicilor de inteligență artificială și învățare automată care, pe baza datelor și a statisticilor folosesc algoritmi inteligenți în acțiunea de a ameliora prevenția primară și în detectarea precoce a unei patologii frecvente și severe precum cancerul de piele. Astfel, tendințele din domeniul tehnologiei demonstrează beneficiile utilizării ML în domeniul sănătății, pentru a schimba maniera de prevenție și predicție a bolilor netransmisibile de tipul cancerului de piele. Algoritmii inteligenți folosiți în învățarea automată se bazează pe predicție, urmărind mai degrabă să anticipeze comportamentul viitor, decât să creeze asocieri între date, astfel fiind unul dintre cele mai utile instrumente în predicția cancerului de piele.

În viitor se dorește ca bolile pacienților să poată fi anticipate, prevenite și rezolvate doar de către tehnologie, lucru care în acest moment nu este posibil fără medicii specialiști care sunt din ce în ce mai puțini. Pe de altă parte, pe piața de IT există experiența, expertiza și infrastructura necesare implementării de proiecte ce vizează studiul, analiza și predicția în comportamentul și evoluția cancerului de piele. Inteligența Artificială ne influențează viețile la scară globală, iar organizațiile realizează pași importanți spre adaptarea la această tehnologie care ne poate oferi noi modalități de rezolvare a problemelor, de luare a deciziilor și de recunoaștere a modelelor.

BIBLIOGRAFIE


1. Abbas, Q. & Celebi, M. (2019). *DermaDeep - A classification of melanomanevus skin lesions using multi-feature fusion of visual features and deep neural network*. Springer.
2. Andre, E., Brett, K., Roberto, A. N., Justin, K., Susan, M. S., Helen, M. B. & Sebastian, T. (2017). *Dermatologist-level classification of skin cancer with deep neural networks*. Nature, vol. 542, 115-118.
3. Asimov, I. (1942). *Runaround - Short story*. Astounding Science Fiction.
4. Barbu, D.-C. (2019). *Soluții de prelucrare specifice Big Data*. Revista Română de Informatică și Automatică (Romanian Journal of Information Technology and Automatic Control ISSN 1220-1758, Vol. 29, No.2, 35-48.
5. Das, K., Cockerell, C., Patil, A., Pietkiewicz, P., Giulini, M., Grabbe, S. & Goldust, M. (2021). *Machine Learning and Its Application in Skin Cancer*. International Journal of Environmental Research and Public Health.
6. Du, A., Emam, S. & Gniadecki, R. (2020). *Review of Machine Learning in Predicting Dermatological Outcomes*. PMC Pub Med Central.
7. Goodfellow, I., Bengio, Y. & Courville, A. (2016). *Deep Learning*. Cambridge, MA: MIT Press.
8. Institutul Național de Sănătate Publică (2022). INSP. Preluat de pe www.insp.gov.ro
9. Marsland, S. (2011). *Machine learning: an algorithmic perspective*. CRC Press, Boca Raton, FL.
10. Mustafa, S., Dauda, A. & Dauda, M. (2017). *Image processing and SVM classification for melanoma detection*. International Conference on Computing Networking and Informatics (ICCNI). Lagos, Nigeria.
11. Official Journal of the European Union (2017). *Civil Law Rules on Robotics*. <https://eur-lex.europa.eu/legal-content/EN/TXT/HTML/?uri=CELEX:52017IP0051&rid=9>.
12. Parlamentul European (2022). *Raport referitor la consolidarea Europei în lupta împotriva cancerului - către o strategie cuprinzătoare și coordonată*. https://www.europarl.europa.eu/doceo/document/A-9-2022-0001_RO.html.
13. Roffman, D., Hart, G., Girardi, M., Ko, C. J. & Deng, J. (2018). *Predicting non-melanoma skin cancer via a multi-parameterized artificial neural network*. Sci Rep nr. 8.
14. Rosenblatt, F. (1986). *Principles of Neurodynamics: Perceptors and the Theory of Brain Mechanisms*. Brain Theory, pp. 245-248. Von der Marlsburg, Christoph.
15. Takiddin, A., Schneider, J., Yang, Y., Abd-Alrazaq, A. & Househ, M. (2021). *Artificial Intelligence for Skin Cancer Detection: Scoping Review*. Journal of. Med. Internet Res., Vol. 23, No. 11.

16. Wang, H.-H., Wang, Y.-H., Liang, C.-W. & Li, Y.-C. (2019). *Assessment of Deep Learning Using Nonimaging Information and Sequential Medical Records to Develop a Prediction Model for Nonmelanoma Skin Cancer*. JAMA Dermatology.
17. World Health Organization (2022). *A short guide to cancer screening - Increase effectiveness, maximize benefits and minimize harm*. Copenhagen: WHO Regional Office for Europe.
18. Zhang, L., Gao, H.-J., Zhang, J. & Badami, B. (2020/2019). *Optimization of the Convolutional Neural Networks for Automatic Detection of Skin Cancer*. De Gruyter, Journal Open Med., vol. 15, 27-37.



Ioana PETCU este cercetător științific în cadrul Institutului Național de Cercetare– Dezvoltare în Informatică – ICI București și este doctor în științe economice din anul 2007 la Academia de Studii Economice din București - Facultatea de Cibernetică și Informatică Economică. Manager de proiect cu o experiență de peste 20 de ani în coordonarea proiectelor IT, Ioana Petcu a implementat cu succes un număr mare de aplicații software atât în companii cu capital de stat cât și private, românești și internaționale. Deține o diplomă postuniversitară în “Inovare publică și strategii de orașe inteligente” de la Universitatea Națională de Studii Politice și Administrație Publică. A obținut certificare în Managementul de Proiect, Managementul Securității Informațiilor, Protecția Datelor, Expert Informații în Afaceri și Protecția Infrastructurilor Critice. A ocupat funcția de lector universitar la Facultatea de Cibernetică Economică, Statistică și Informatică, a publicat o serie de articole științifice în reviste și a participat la diverse conferințe științifice naționale și internaționale. Activitatea sa științifică include o carte publicată în domeniul modelării cibernetice bazate pe agenți și un curs de cibernetică economică. Este membru al Asociației Române pentru Smart City deținând calitatea de expert. În calitate de cercetător științific a participat la diverse proiecte finanțate din fonduri europene, făcând parte din echipa de cercetare a Universității de Medicină și Farmacie “Carol Davila” din București, în cadrul unui proiect al Programului Orizont 2020.

Ioana PETCU is a Scientific Researcher at the National Institute for Research and Development in Informatics – ICI Bucharest, holds a PhD degree in economics science since 2007 from the Bucharest University of Economic Studies - Faculty of Cybernetics and Economic Informatics. Ioana Petcu is an experienced project manager, with over 20 years’ experience in coordinating IT projects, successfully implementing a large number of software applications both in state capital companies and private (Romanian and international). She holds a postgraduate degree in Public Innovation and Smart Cities Strategies from the National University of Political Studies and Public Administration. She obtained certification in Project Management, Security Information, Data Protection, Business Competitive Intelligence and Critical Infrastructure Protection. Held the position of university lecturer in The Faculty of Economic Cybernetics, Statistics and Informatics and she published various scientific articles and presented scientific papers at international scientific conferences. Her scientific activity includes a published book about the field of agent based cybernetic modelling and an economics cybernetics course. She is a member of the Romanian Association for Smart City as an expert. As a scientific researcher, she has participated in various projects funded by European funds, being part of research team of Carol Davila University of Medicine and Pharmacy Bucharest in a Horizon 2020 project.



Dragoș-Cătălin BARBU este doctorand în cadrul Academiei de Studii Economice din București, în domeniul „Informatică Economică”, a absolvit Facultatea de Matematică și Informatică din cadrul Universității din București și deține o diplomă de master în domeniul „Informaticii Teoretice” din cadrul Departamentului de Informatică, Facultatea de Matematică și Informatică, Universitatea din București. În prezent deține funcția de Șef Serviciu „Cloud Computing” și este Cercetător Științific gradul III în cadrul Institutului Național de Cercetare-Dezvoltare în Informatică – ICI București, desfășurând activitate de cercetare în domeniul TIC de peste 15 ani. Este reprezentant supleant al României în Consiliul de conducere al Întreprinderii Comune Europene de Calcul de Înaltă Performanță (EuroHPC JU) și, de asemenea, delegatul român în Consiliul de conducere al European Open Science Cloud (EOSC). A coordonat proiecte naționale în domeniul „Cloud Computing”, securitate informatică, servicii electronice, librării digitale, inteligență artificială și realitate îmbogățită, a participat la realizarea a peste 25 de proiecte naționale, 8 proiecte internaționale, și a publicat peste 30 de articole la nivel național și 4 articole la nivel internațional.

Dragoș-Cătălin BARBU is a PhD candidate at the University of Economic Studies in Bucharest, he graduated from the Faculty of Mathematics and Computer Science at the University of Bucharest and holds a master's degree in the field of Theoretical Informatics from the Department of Computer Science, the Faculty of Mathematics and Computer Science, the University of Bucharest. He is the Head of the “Cloud Computing” Department and a Senior Researcher III within the National Institute for Research and Development in Informatics – ICI Bucharest. Dragoș-Cătălin Barbu has been carrying out research activity in the ICT field for over 15 years, coordinating national projects in the field of “Cloud Computing”, computer security, electronic services, digital libraries, artificial intelligence and augmented reality. He is the Romanian Substitute Representative in the Governing Board of European High Performance Computing Joint Undertaking (EuroHPC) and also the Romanian delegate in the European Open Science Cloud (EOSC) Governance Board. Moreover, he participated in the implementation of more than 25 national projects, 8 international projects and he has published over 30 articles at a national level and 4 articles at an international level.



Silvius-Ioan NEGOIȚĂ este doctor în științe medicale, Șeful Secției ATI din cadrul Spitalului Clinic de Urgență Elias din București și Șef Lucrări în cadrul Universității de Medicină și Farmacie „Carol Davila” din București. A absolvit Universitatea de Medicină și Farmacie „Carol Davila” din București în anul 1998, urmând rezidențiatul în cadrul Clinicii ATI a Spitalului Clinic Militar Central București, apoi ocupând postul de medic specialist în cadrul Secției ATI, Spitalul Clinic de Urgență Elias din București. A fost implicat în proiecte de învățământ și cercetare, iar din anul 2009 este asistent universitar. A participat în calitate de membru fondator la înființarea

Asociației Române pentru Cale Aeriană Dificilă și s-a alăturat echipei de profil ca speaker/trainer. Totodată, a fost implicat ca lector/formator și organizator în cadrul Congresului SRATI, ROSPEN, Simpozioanelor de ventilație mecanică, cursuri de anestezie inhalatorie și simulare în ventilația mecanică. A fost cooptat ca membru în echipa a șase granturi/proiecte internaționale și în tot atâtea studii clinice sub egida ESA și ESICM. De asemenea, este autor principal sau coautor la 28 articole indexate ISI Thomson Reuters.

Silviu-Ioan NEGOIȚĂ, holds a PhD degree in medical science, Head of the ATI Department at Elias Hospital and Lecturer at the Carol Davila University of Medicine and Pharmacy, he graduated from UMF Carol Davila in 1998, following the residency at the ATI Clinic of the Central Military Clinical Hospital Bucharest, having the position of specialist ATI doctor at SUU Elias. He has been involved in education and research projects and has been an assistant professor since 2009. He participated as a founding member in the establishment of the Romanian Association for Difficult Airways and joined the profile team as a speaker and trainer. He was also involved as a trainer and organizer in the SRATI Conference, ROSPEN, Mechanical Ventilation Symposiums, inhalation anaesthesia courses and simulation in mechanical ventilation. He was co-opted as a member of the team of 6 international projects and in as many clinical trials under the auspices of ESA and ESICM. He is also the lead author or co-author of 28 ISI Thomson Reuters indexed articles.