

Deep Learning. Viitorul inteligenței artificiale și impactul acesteia asupra dezvoltării tehnologiei

Catalin VRABIE,

Scoala Națională de Studii Politice și Administrative (SNSPA), București, România
catalin.vrabie@snsa.ro

Abstract

Ceea ce își propune acest eseu este prezentarea conceptelor *Machine Learning (ML)* și *Deep Learning (DL)*, din domeniul științei informatice, concepte aflate acum în plin avânt mediatic dar, evident, și tehnologic. Pe măsură ce ne apropiem de cea de-a șaptezecoa aniversare a noțiunii de inteligență artificială (*AI*) (anul 2026), investițiile globale în acest domeniu au atins un nivel record. În ultimii ani, tehnologiile mobile și cele *cloud* au apărut ca paradigme dominante, oferind o multitudine de oportunități întregii societăți începând cu comunitățile de utilizatori și până la cele de cercetători și dezvoltatori; acum însă credem că inteligența artificială, în special *Deep Learning*, ar putea deține un potențial și mai mare, depășindu-l astfel pe cel al tehnologiile anterioare. Motivul din spatele acestei convingeri va deveni din ce în ce mai clar în paginile care urmează.

Keywords: Machine Learning, Natural Language Processing, Robotics.

1. Introducere

Pentru a înțelege pe deplin implicațiile acestor tehnologii și a transformărilor pe care le promet întregii societăți, trebuie mai întâi să înțelegem ce înseamnă inteligența artificială, ce înseamnă *Machine Learning* și, evident, ce înseamnă *Deep Learning*?

„Inteligența artificială este unul dintre cele mai profunde concepte la care lucrăm ca umanitate, este mai profundă decât focul sau electricitatea”, a spus Sundar Pichai – CEO-ul *Alphabet*, în cadrul întâlnirii anuale din 2020 a Forumului Economic Mondial de la *Davos*, Elveția [1].

„Cred că lucrăm la una dintre tehnologiile cu cea mai mare putere de transformare a lumii pe care le-a văzut vreodată industria noastră. Cea mai mare investiție a noastră este în dezvoltarea inteligenței artificiale și în integrarea acesteia în fiecare dintre produsele noastre”, a declarat Mark Zuckerberg – CEO-ul *Meta*, pe blogul companiei (2023) [2].

Bill Gates – co-fondator *Microsoft*, a declarat pe celebrul său blog – *GatesNotes* (2023), că ”Inteligența artificială este la fel de revoluționară ca telefoanele mobile și Internetul” [3].

Așa cum toată lumea știe deja, *Silicon Valley* este considerat centrul lumii în ceea ce privește dezvoltarea tehnologiilor viitorului. Inteligența artificială a ocupat un loc deosebit de important în strategiile de cercetare și dezvoltare ale celor mai influente companii de acolo și, evident, nu numai. Manageri de top, precum cei citați, dar și mulți alții, așa cum vom vedea pe parcursul articolului, au declarat că inteligența artificială formează nucleul operațiunilor companiilor pe care le conduc – aceasta fiind forța motrice din spatele strategiilor lor de cercetare și dezvoltare. Încă din 2016, Sundar a declarat că „în curând vom trece de la o lume bazată pe tehnologiile *mobile* la una bazată pe cele *AI*” [4].

Întrebarea care apare în acest context este: ce a generat schimbarea și care este natura acestei transformări continue? Pentru a putea înțelege însă răspunsul la această întrebare este nevoie de o privire în perspectivă asupra dezvoltării conceptului, de a face câțiva pași

înapoi în timp, și începem astfel prin a prezenta, foarte pe scurt, traseul evoluției acestor tehnologii.

1.1. (Deci) puțină istorie

Din fericire, începuturile nu numai că sunt bine documentate, dar se cunoaște cu exactitate momentul și locul în care conceptul de inteligență artificială (termenul consacrat în literatura de specialitate este *Artificial Intelligence* de unde și acronimul *AI*), a luat oficial naștere: vara anului 1956, în *Dartmouth*, Statele Unite. În esență, atunci și acolo a fost pentru prima dată când *Inteligența Artificială* a apărut oficial în inițiative științifice [5].

Conceptul de a construi mașini care să poată imita acțiunile umane, sau să dea dovadă de inteligență umană, a captivat de mult timp imaginația. Grecii antici vorbeau de statui care prindeau viață, în timp ce alte civilizații timpurii, cum ar fi chinezii și egiptenii, au creat roboți¹ acționați mecanic care prezentau comportamente asemănătoare cu cele umane [6, 7, 8]. Literatura, de asemenea, are partea sa de astfel de noțiuni, *Frankenstein* al lui Mary Shelley fiind un prim exemplu (1818) [9]. Aceste cazuri sunt ecoul unei dorințe umane adânc înrădăcinate – aspirația de a crea entități care ar putea reflecta caracteristicile și comportamentele omului.

Cu toate acestea, așa cum am menționat, geneza oficială a *AI*, așa cum o cunoaștem astăzi, este marcată de vara anului 1956, când un colectiv de cercetători ambițioși s-a întâlnit, așa cum am spus, la *Dartmouth*, inițiind o serie de proiecte ce urmăreau un obiectiv specific: *conceperea unor computere care să imite comportamentul uman* [5].




Fig. 1. Participanți ai primului eveniment științific privind Inteligența Artificială – *Dartmouth*, 1956
Source: @macloo – Utilizator Twitter Mindy McAdams, profesor de jurnalism digital, Universitatea din Florida.

¹ *Automatons* – pentru o înțelegere mai bună a conceptului recomand spre citire pagina *Wikipedia* dedicată acestora: <https://en.wikipedia.org/wiki/Automaton>

Marvin Minsky, John McCarthy, Claude Shannon, Nathaniel Rochester și alte nume din domeniul matematicii și al informaticii s-au adunat în acea vară memorabilă cu un scop comun de a face cercetare în vederea construirii unei entități inteligente. Astfel, din punct de vedere academic, ca ramură a informaticii, nașterea *Inteligenței Artificiale* este marcată în vara anului 1956.

Obiectivele lor de cercetare – sau întrebările la care își doreau să răspundă, au fost cât se poate de explicite: *Având în vedere complexitatea computerelor și cea de netăgăduit a oamenilor, ar putea membrii proiectului programa computerele pentru a îndeplini sarcinile cognitive complexe pe care le pot face oamenii?*

Ar putea computerele, în esență, să învețe să raționeze? Aceasta însemna să permită computerelor să îndeplinească sarcini precum jucarea unor partide de șah, rezolvarea problemelor algebrice, demonstrarea teoremelor geometrice și diagnosticarea bolilor.

Fiecare dintre aceste sarcini implică un raționament, în cadrul căruia este prezentată o problemă, urmând a se găsi o cale logică către răspuns – jocul de șah este un bun exemplu de raționament pentru un computer, deoarece jucătorul (în acest caz, computerul) trebuie să explice de ce a ales o anumită mutare dintr-un număr uriaș de alte mutări posibile [10] – merită adăugat aici faptul că șahul a fost adesea considerat *Drosophila Melanogaster* în cercetarea întreprinsă în zona inteligenței artificiale [11, 12].

Un obiectiv suplimentar a fost acela de *a învăța computerele să dobândească cunoștințe despre lumea reală*. Pentru ca un computer să înțeleagă și să se implice cu adevărat în relația cu oamenii, trebuie să înțeleagă și să interacționeze cu lumea reală. Acest lucru implică înțelegerea unor concepte precum *obiecte* și *oameni* precum și *limbajul* pe care cei din urmă îl folosesc pentru a comunica. Pentru a realiza acest lucru, elementele naturale omului trebuiau să fie codificate într-un limbaj paralel, destinat înțelegerii lui de un computer. Ca urmare au fost create limbaje de programare (așa cum au ajuns să fie denumite ele ulterior), dintre care îl amintim aici pe *Lisp*², inventat de John McCarthy în 1959 [13].

Cel de-al treilea aspect pe care cercetătorii l-au urmărit, a fost *să înzestreze computerele cu modele de înțelegere a modului de planificare și navigare prin lumea în care noi trăim*. Acest lucru implică înțelegerea modului de a se deplasa dintr-un punct în altul, recunoașterea ușilor, găsirea căilor de acces și distingerea între zonele sigure și cele nesigure (cum ar fi scările). În plus, atunci când există mai multe rute către o anumită destinație, computerul ar trebui să fie capabil să facă alegeri în funcție de elemente de context. Toate acestea intră sub incidența planificării și navigării, pe care cercetătorii acelor vremuri s-au străduit să le înglobeze în memoria computerelor.

Primele încercări de natura ultimelor descrise mai sus au avut loc la Institutul de Cercetare a Universității *Stanford* (*Stanford Research Institute – SRI*), la mijlocul anilor 1960, odată cu crearea primului robot autonom. Această mașină, echipată cu camere de luat vederi și

² Acronim al conceptului de *List processing*.

roți, a reprezentat pasul inițial în acest demers absolut revoluționar [14] – vom reveni asupra acestor idei.




Fig. 2. Robotul *Shakey* creat la *Stanford* între 1966 și 1972
Source: https://en.wikipedia.org/wiki/Shakey_the_robot

Așa cum am menționat, o sarcină suplimentară a fost aceea de a face computerele să înțeleagă limbajul: cum să îl articuleze și să îl înțeleagă, cum să formuleze propoziții și cum să înțeleagă contextul acestor propoziții. Noi, oamenii, folosim zilnic limbajul ca un instrument sofisticat și puternic pentru a ne exprima gândurile, emoțiile și observațiile despre lume. Obiectivul membrilor proiectului a fost de a permite computerelor să emuleze cât mai mult posibil din acest proces complex.

Primele experimente de procesare a limbajului natural (*Natural Language Processing – NLP*) au fost efectuate la Universitatea *Georgetown*, folosind un *mainframe IBM*. Scopul a fost de a facilita traducerea între limbile engleză și rusă [15]. Vom reveni și asupra acestui experiment foarte interesant în paginile următoare ale articolului.

O altă capacitate crucială pe care cercetătorii intenționau să o „transmită” computerelor era *percepția* – înțelegerea modului în care noi, ca oameni, vedem, auzim și simțim lucrurile din mediul nostru înconjurător. Cercetătorii de la *Dartmouth* au emis ipoteza că, *pentru a ajunge la nivelul de inteligență al oamenilor, computerele ar trebui să învețe cum să perceapă lumea prin diverse simțuri, cum ar fi vederea, auzul, atingerea și mirosul*. Dintre acestea, ei credeau că vederea era cea mai fezabilă problemă de abordat.

În consecință, Marvin Minsky, în laboratorul său de la *Massachusetts Institute of Technology (MIT)*, a inițiat primul set de experimente pentru a determina în ce condiții computerele, atunci când sunt alimentate cu intrări video prin intermediul camerelor de luat vederi, pot înțelege lumea în același mod în care o facem noi [16]. Scopul era de a le învăța pe acestea să discearnă obiecte și să reacționeze în consecință – de exemplu recunoașterea unui set de cuburi și/sau alte obiecte tridimensionale, înțelegerea formei acestora și structurii pe care împreună o formează sau o pot forma – cam la fel cum învață, prin joc, copiii la vârste foarte fragede, să construiască.

Obiectivul stabilit în vara anului 1956 a fost remarcabil de ambițios. Este esențial să ne amintim aici că cel mai avansat calculator de la acea vreme era un *mainframe*, care avea nevoie pentru interfațare de cartele perforate. Prin urmare, cercetătorii care s-au reunit în acea memorabilă vară erau cu adevărat înaintea timpului lor.

Cu toate acestea, a urmat o succesiune de perioade de avânt (dar și de declin), marcate de demonstrații extrem de impresionante care au atras cercetări suplimentare, finanțări și inițiative de înființare a *startup*-urilor din zona de *IT*. Aceste faze aveau totuși să își urmeze cursul și să atingă în cele din urmă și un punct de minim atât de jos încât a apărut un scepticism profund cu privire la fezabilitatea creării inteligenței artificiale.

Astfel de cicluri nu au avut loc doar o singură dată, ci de șase sau șapte ori. În continuare, vom oferi câteva exemple pentru a ilustra de ce aceste valuri de entuziasm au fost urmate de deziluzii atât de profunde. Ele au intrat atât de adânc în conștiința cercetătorilor încât au primit chiar și un nume: *AI winters* – un nume care sugerează o iarnă nucleară (deoarece în urma unui atac nuclear nu ar mai fi posibil pentru nicio formă de viață să existe timp de decenii în zonele afectate de radiații). Analogia aplicată la cercetarea în domeniul *AI* sugerează că, din când în când, domeniul a fost atât de afectat de dificultăți încât progresul ulterior părea imposibil. În consecință, finanțarea a fost, de asemenea, oprită pentru perioade lungi de timp.

Acum, să analizăm câteva dintre aceste cicluri de avânt și declin. Prima „iarnă *AI*” a fost declansată de inițiativele ce vizau traducerea automatizată [17]. Pentru a pune acest lucru în context trebuie menționat că Statele Unite se îndreptau spre Războiul Rece astfel încât exista o nevoie stringentă de a traduce texte din limba rusă în engleză și viceversa. Lipsa unor vorbitori nativi de rusă în SUA a dus la ideea creării unor mașini capabile să efectueze astfel de operațiuni. Tocmai acesta a și fost experimentul realizat în 1954 de către, așa cum am menționat mai sus, cercetătorii de la Universitatea *Georgetown* și *IBM*. Aceștia au prezentat primul sistem capabil de astfel de traduceri, traducând șazececi de propoziții din rusă în engleză cu ajutorul unei mașini. Demonstrația a fost un succes răsunător: folosind

cartele perforate, un operator introducea propoziții în limba rusă în calculator, acesta la rândul său le procesa și, ca rezultat, dădea un set separat de cartele perforate cu traducerea în limba engleză. Experimentul, pentru propozițiile alese, a fost remarcabil de precis. Această demonstrație a declanșat un val de cheltuieli pentru cercetare și dezvoltare, toate dedicate dezvoltării de sisteme de traducere universale.

Cu toate acestea, se pare că această sarcină era extraordinar de dificilă. Pentru a ilustra, să luăm în considerare exemplul care a fost folosit la vremea respectivă și anume propoziția *The Spirit is willing, but the flesh is weak* [18]. Pentru a verifica acuratețea, multe dintre aceste sisteme inițiale au fost testate prin introducerea propoziției traduse înapoi într-un traducător din rusă în engleză. Utilizând aceste sisteme, cu propoziția în limba engleză pe care am menționat-o, rezultatul a fost: *Whisky-ul este tare, dar carnea este putredă!* Reflectând asupra acestui lucru, se poate înțelege cu ușurință de ce s-a produs o astfel de traducere – este vorba, în esență, de o traducere cuvânt cu cuvânt destul de bună. Cu toate acestea, chiar și pentru un vorbitor mediu de limba engleză, este la fel de clar că traducerea este improprie, ea nesurprinzând sensul sau, ceea ce un informatician ar numi: *semantica propoziției*. În schimb, a realizat ceea ce tot un informatician ar numi *o traducere sintactică sau o traducere mot-a-mot*.

Și, într-adevăr, ca traducere *mot-a-mot*, nu este tocmai greșită. Dacă însă astfel de tipuri de erori se acumulează în diverse propoziții dintr-un corpus mare de text, sensul dorit devine în întregime distorsionat. Acest lucru a dus la apariția primei ierni a inteligenței artificiale – un sentiment de deziluzie în jurul capacității de a capta sensul autentic al textelor traduse. Perspectiva ca mașinile să înțeleagă contextul, expresiile idiomatice și alte elemente care nu sunt prezente în mod explicit în cuvintele unei propoziții părea descurajantă, iar cercetătorii, alături de cei care erau atenți la eforturile acestora, au fost la rândul lor descurajați în a mai acorda atenție acestor inițiative.

Un comitet format din economiști și politicieni, denumit *Automated Language Processing Advisory Committee (ALPAC)*, a declarat că progresul în domeniul traducerii automate era atât de lent încât investițiile suplimentare ar însemna irosirea unor bani buni, sugerând că astfel de cheltuieli ar trebui să fie oprite [19]... ceea ce s-a și întâmplat.

Cercetătorii au trecut atunci la o abordare radical diferită. Deoarece traducerea oricărui limbaj în oricare altul părea prea ambițioasă, au decis să limiteze spațiul de gândire al mașinilor la domenii foarte specifice. Acest lucru a dus la cercetări în jurul a ceea ce a ajuns să fie cunoscut sub numele de *micro-worlds*. Scopul era de a restrânge lumea reală într-una mai mică și de a încerca să facă mai multe progrese în înțelegerea aceluia context specific.

Un exemplu de *micro-world* ar putea fi configurația de blocuri a lui Marvin Minsky care, analizată de un robot dotat cu un sistem de camere, să o poată manipula. Obiectivul într-o astfel de *micro-world* în domeniul limbajului uman era de a programa sistemul pentru a înțelege propoziții de genul: *Ridică un cub; Ridică un cub roșu; Pune cubul pe sferă...* și așa mai departe. Sistemul ar trebui apoi să discearnă dacă astfel de acțiuni sunt fezabile. De exemplu, ar putea fi amplasat un cub pe o sferă? Având în vedere forma naturală a acestor

obiecte, sarcina nu este tocmai una ușoară și, prin urmare, sistemul ar trebui să răspundă cu *Nu este posibil!*

Aceasta ar fi un exemplu de *micro-world*: limitarea lumii la un domeniu de aplicare îngust și evaluarea progreselor în ideea capitalizării lor.

Un alt exemplu al unei astfel de *micro-world* a fost sistemul dezvoltat de Joseph Weizenbaum – sistem cunoscut sub numele de *ELIZA*, care continuă să fie și astăzi un subiect de studiu în cadrul cursurilor de inteligență artificială din întreaga lume [20]. Sistemul *ELIZA* se învârtea în jurul terapiei prin conversație – simula o vizită la un terapeut pentru a discuta un set de probleme din viața personală a unei persoane. Scopul era de a crea o inteligență artificială capabilă să se angajeze într-o conversație similară cu cea a unui psiholog clinician – dar, bineînțeles, la acea vreme, limitată doar la *input*-uri sub formă de text. Mai jos redau un exemplu real de funcționare a unui astfel de sistem [21] – poate fi testat căutând pe *web*: *ELIZA: a very basic Rogerian psychotherapist chatbot* [21]):

- *Persoană: Bărbații sunt toți la fel.*
- *ELIZA: În ce sens?*
- *Persoană: Mereu mă deranjează cu câte ceva.*
- *ELIZA: Vă puteți gândi la un exemplu concret?*
- *Persoană: Ei bine, prietenul meu m-a făcut să vin aici.*
- *ELIZA: Prietenul dvs. v-a făcut să veniți aici?*
- *Persoană: Spune că sunt deprimată în cea mai mare parte a timpului.*
- *ELIZA: Îmi pare rău să aud că sunteți deprimată.*
- *Persoană: Este adevărat. Sunt nefericită.*
- *ELIZA: Credeți că venind aici vă va ajuta să nu mai fiți nefericită?*
- *Persoană: Am nevoie de ajutor, asta pare sigur.*
- *ELIZA: Ce ar însemna pentru dvs. acest ajutor?*
- *Persoană: Poate că aș putea învăța să mă înțeleg cu mama mea.*
- *ELIZA: Spuneți-mi mai multe despre familia dvs.*

Acest exemplu prezintă o interacțiune incredibil de realistă. Ne putem imagina cu ușurință un terapeut care vorbește cu adevărat și care răspunde în același mod în care a făcut-o computerul. Entuziasmul a fost palpabil, deoarece terapia prin conversație reprezintă o interpretare sofisticată a limbii și o înțelegere nuanțată a oamenilor, a relațiilor lor și a luptelor pe care aceștia le poartă, exemplul fiind astfel foarte convingător.

Cu toate acestea, a apărut o problemă semnificativă: în momentul în care cineva încerca să converseze cu computerul despre orice subiect care nu se încadra în cadrul unei conversații tipice de terapie – practic atunci când se ieșea din sfera *micro-world*-ului în care acesta fusese programat, iluzia se destrăma imediat. Răspunsurile computerului deveneau absurde și chiar halucinante; părea că se joacă pur și simplu cu limbajul și, evident, nu acesta era scopul. La acea vreme părea ca și cum mașina ar fi încercat să manipuleze sintaxa propozițiilor în limba engleză pentru a păcăli pe cineva să creadă că înțelege cu adevărat,

când, în realitate, nu făcea decât să rearanjeze cuvintele și să caute cuvinte cheie specifice precum „mamă” sau „depresie” pentru a reacționa în consecință. Iluzia se spulbera în momentul în care cineva menționa un cuvânt ce nu era inclus în dicționarul programat inițial.

Asta a condus la cea de-a doua „iarnă AI”. Sistemele de această natură, extrem de constrânse, funcționau excelent în contexte foarte specifice, dar se prăbușeau imediat ce cineva se aventura, chiar și puțin, în afara scenariului. Un raport al guvernului britanic a sintetizat acest sentiment, concluzionând că „AI nu a reușit să atingă niciunul dintre obiectivele sale mărețe” [22] – și odată cu acest raport (care de altfel l-a și făcut celebru pe James Lighthill, autorul lui) s-a tăiat din nou finanțarea pentru cercetarea în domeniu.

În jurul anului 1980 au început să apară așa numitele *sisteme expert* [23]. Geneza reală a acestei abordări a fost în anii '60, dar *startup*-urile au început să se formeze serios în jurul acestui concept la sfârșitul anilor '70 și începutul anilor '80. Raționamentul a fost următorul: traducerea automată a fost un eșec – computerele nu puteau converti orice text, ales aleatoriu, din engleză în rusă și viceversa; la fel s-a întâmplat și cu aceste *micro-world* de care am vorbit mai sus, medii în care cercetătorii au încercat să emuleze de la zero domenii foarte simple și constrânse așa cum ar fi fost „lumea” corpurilor geometrice sau a psihoterapiei. Noul val de idei – aceste *sisteme expert*, a presupus o tactică diferită; dacă „învățarea” computerelor de la zero, la fel cum copiii își însușesc cunoștințele primite de la părinți, nu a avut succes, poate merge invers.

Cercetătorii au început să se concentreze asupra sarcinilor care necesitau abilități intelectuale complexe, de exemplu: diagnosticarea bolilor sau executarea sarcinilor unui analist-programator. Cu alte cuvinte, această nouă abordare încerca să codifice domenii complexe în ceea ce se numea *sisteme expert* [23]. Conceptul a fost simplu: identificarea unui expert și apoi transcrierea cunoștințelor sale în aceste sisteme – cercetătorii considerând că mașinile ar putea avea ca obiectiv reproducerea comportamentului experților.

Așa cum am spus, primele exemple în acest sens pot fi văzute în 1965, când Edward Feigenbaum și Carl Djerassi au dezvoltat un sistem numit *Dendral* [24]. Acest sistem a fost conceput pentru a interpreta datele provenite de la un spectrometru de masă pentru a identifica moleculele reprezentate de aceste date – rezultatele au fost din nou impresionante. Succesul l-a stimulat pe Edward Shortliffe – cercetător la *Stanford*, să creeze în 1972 un program cunoscut sub numele de *MYCIN* [25]. Acesta a fost conceput pentru a diagnostica bolile infecțioase ale sângelui prin analizarea simptomelor și a datelor din sânge în vederea emiterii unui diagnostic.

În mod remarcabil, acest sistem a atins o rată de acuratețe de aproximativ 50-60%, comparabilă cu acuratețea de diagnosticare a medicilor umani [25]. Este astfel ușor de înțeles entuziasmul cercetătorilor care s-au gândit că, dacă ar fi posibil să codifice acest comportament de expert într-un set de reguli pe care un computer le poate procesa, poate că următorul pas ar fi dezvoltarea câtorva sute de sisteme expert similare și astfel majoritatea problemelor oamenilor ar putea fi rezolvate.

Această abordare a întruchipat cu adevărat optimismul epocii; se credea că este viitorul inteligenței artificiale. Strategia avea în vedere concentrarea pe sarcini specifice în ideea construirii unui sistem expert în jurul fiecăreia. Se presupunea că fiecare astfel de sistem va fi din ce în ce mai ușor de construit (grație lecțiilor învățate pe parcurs) și, prin iterație continuă, crearea a mii de astfel de sisteme va duce în cele din urmă la inteligență artificială. Ideea era de a încapsula expertiza chimiștilor, medicilor, profesorilor, matematicienilor și așa mai departe, într-un sistem (de sisteme) care la final ar putea emula inteligența umană a tuturor acestora.

Investițiile *IBM* de la acea vreme reflectau convingerea că dezvoltarea inteligenței artificiale era inevitabilă. Prin urmare, aveau nevoie de un instrument de dezvoltare a sistemelor expert – un *software*, pentru ca dezvoltatorii să construiască astfel de sisteme expert, în așa fel încât acestea să poată fi produse rapid, iar compania să poată atinge obiectivul preconizat prin această metodă. În această perioadă au apărut numeroase *startup*-uri, cel mai notabil fiind *Symbolics* [26] care era construit în jurul unei mașini *Lisp* – am amintit mai sus de John McCarthy care l-a inventat. Întreaga comunitate de cercetători a fost (din nou) incredibil de entuziastă, convinsă că aceasta era, fără îndoială, calea de urmat.

Din păcate, construirea unui sistem expert nu a oferit niciun avantaj în crearea următorului. Procesul de identificare a unui expert, de înțelegere a activității acestuia și de codificare a setului de reguli a rămas lung, anevoios și nu a oferit prea multe avantaje atunci când s-a încercat reproducerea lui pentru un alt expert. Acest lucru a dus la prăbușirea sistemelor expert, ilustrată cel mai bine de prăbușirea companiei *Symbolics* în 1987 [27], fapt ce a dus la cea de-a treia „iarnă a AI” (University of Washington, 2006).

1.2. Punctul critic

Apariția unor concepte precum *Deep Learning* – subdomeniu al *Machine Learning* [29, 30] a marcat o schimbare substanțială în abordarea AI.

Cele mai multe dintre tehnicile menționate anterior au fost fundamentate pe ideea programării computerelor prin încercarea de a înțelege și codifica comportamentul sau limbajul oamenilor în reguli, care apoi să fie introduse în mașini. Tehnicile *Deep Learning* – un concept inspirat de creierul uman (vom reveni la acest aspect), funcționează prin alimentarea structurilor de date cu cantități mari (a se citi *uriașe*) de date, iar apoi, prin utilizarea de algoritmi, programarea mașinilor pentru a învăța singure pe baza acestor date. Este o abordare fundamental diferită de cele urmărite anterior.

Totuși, bazele acestor idei vin încă din anii 1940, de la doi cercetători, și anume neurologul Warren McCulloch și logisticianul Walter Pitts [31], care, încă de la acea vreme, au propus conceptul de modelare a structurilor de date și a algoritmilor pe baza creierului uman – ceea ce astăzi numim o rețea neuronală (*Neural Network - NN*) [32]. De-a lungul timpului, numeroși cercetători au rafinat și dezvoltat aceste idei pentru a spori viteza algoritmilor, a le îmbunătăți capacitățile de învățare în vederea sporirii acurateței și pentru a le crește performanța predictivă [33, 34, 35, 36].

Deși acest articol nu își propune să ofere o istorie completă, pentru cei interesați să afle mai multe, recomandăm pe scurt, în continuare, câteva resurse bibliografice care completează lista cercetătorilor și cercetărilor ce au contribuit la aceste idei și care astfel ar putea ajuta la o întregire a imaginii progresului din domeniu.

Yann LeCun – care ocupă în prezent funcția de *Chief AI Scientist* la *Meta/Facebook*, a folosit rețelele neuronale, încă de la sfârșitul anilor '80, în încercarea de a recunoaște codurile poștale scrise de mână [37, 38].

Ulterior, Geoffrey Hinton și Yoshua Bengio – Hinton a făcut parte până de curând din echipa de cercetare în domeniul inteligenței artificiale de la *Google*, în timp ce Bengio este profesor la Universitatea din *Montreal*, au dezvoltat aceste rețele neuronale în ceea ce se numește *Deep Belief Networks* [39]. Cercetările lor au influențat în mod direct tehnologiile pe care astăzi le folosim zi de zi; de exemplu, atunci când interacționăm cu dispozitivele mobile folosind comenzi vocale, algoritmi de conversie a vorbirii în text sunt descendenți direcți ai eforturilor celor doi. Împreună cu Yann LeCun, Geoffrey Hinton și Yoshua Bengio au primit în 2019 cel mai prestigios premiu în domeniul informaticii – echivalentul premiului *Nobel*, și anume *Turing Award*, pentru contribuția lor la domeniul *AI* [40].

Un alt contribuitor important la cercetarea în domeniul rețelelor neuronale este Jürgen Schmidhuber, un cercetător german care a introdus ideea unei structuri de date numită *Recurrent Long Short-Term Memories (LSTM)*, integrată cu rețele neuronale de tip *Deep Feed-Forward (DFF)* [41]. Oricât de ciudați și/sau amuzanți ar putea părea acești termeni, toți de fapt reprezintă progrese/îmbunătățiri esențiale ale unei premise fundamentale: rețeaua de neuroni ce formează creierul uman; prin urmare, accentul a fost pus pe proiectarea unor structuri de date și algoritmi care să imite această structură [42].

Continuând istoria rețelelor neuronale și păstrând aceeași idee centrală, *Google* a decis în 2012 să testeze acest lucru. Iar atunci când *Google* intră în luptă, ceea ce oferă în primul rând este volumul – dispune de o multitudine de resurse precum: rezultatele căutărilor efectuate de utilizatori, locația geografică a acestora, diferite alte interogări efectuate de utilizatori, imagini, clipuri etc. Andrew Ng – profesor la *Stanford* a utilizat zece milioane de videoclipuri *YouTube* ca bază de date pentru acest tip de rețele (setul de antrenament pe care l-a folosit a fost realizat din *frame-uri* de 200x200 de pixeli, capturate din aceste videoclipuri) [43].

Un alt aspect cu care *Google* a contribuit semnificativ la idee a fost cel al resurselor de calcul. *Google* folosește ceea ce se numește *distributed computing*, adică utilizează o multitudine de calculatoare și nuclee pentru a procesa cantități uriașe de date – spre deosebire de abordarea clasică în care, pentru volum mare de calcul, se folosea un (singur) *mainframe*. Astfel, pentru acest experiment, compania a pus la dispoziție o mie de computere, fiecare echipat cu șaisprezece nuclee. Aceste mașini au fost puse să lucreze la cele zece milioane de videoclipuri *YouTube* timp de o săptămână, utilizând structura rețelei neuronale construită de Andrew Ng [44].

Interesant, și totodată amuzant, este că, după analiza celor zece milioane de videoclipuri, algoritmi au început să recunoască ce conțin aceste videoclipuri și, aici vine partea amuzantă, deși poate că nu este surprinzător, primele elemente identificate au fost pisicile [45, 46, 47] – se pare că utilizatorii încarcă un număr extrem de mare de videoclipuri cu pisici pe *YouTube*. Cu toate acestea, rețeaua a recunoscut mult mai mult decât atât fiind în esență capabilă să discearnă alte câteva sute de obiecte. De fapt, dintr-o bază de date cu douăzeci de mii de obiecte diferite (din setul de antrenament), algoritmi au recunoscut cu precizie șaisprezece la sută dintre ele în videoclipurile *YouTube* la care sistemul a avut acces [43].

Aspectul frapant aici este că nu a existat niciun expert care să ofere descrieri detaliate ale trăsăturilor unei pisici, cum ar fi nasul, labele, mustățile sau forma ochilor ori a urechilor. În schimb, rețeaua a fost pur și simplu alimentată cu un volum masiv de date, iar aceasta a învățat în mod autonom să le clasifice, fără a fi ghidată de vreun expert sau a se bucura de un set de reguli predefinite. Această abordare, cunoscută sub denumirea de *unsupervised learning*, constituie epicentrul revoluției din industria *AI*. Prin asta, Andrew Ng s-a îndepărtat de metoda de interviu a oamenilor pentru a le extrage expertiza în vederea transferului către computere a acesteia, în schimb, a adoptat o metodologie bazată pe date. Prin simpla alimentare a sistemului cu cantități uriașe de date, computerul a învățat în mod independent să clasifice și să distingă elemente diferite.

Dacă suprapunem experimentul lui Andrew Ng cu încercarea lui Yann LeCun de a recunoaște codurile poștale scrise de mână, observăm că cel din 2012 a folosit o putere de calcul de un milion de ori mai mare și a folosit algoritmi mult mai avansați. Unul dintre motivele pentru care rețelele neuronale sunt atât de în vogă astăzi, în ciuda faptului că acestea au fost cercetate încă din anii 1940, este scala la care se raportează întreaga industrie *AI* în ultimul deceniu.

Pentru a oferi o idee mai clară despre traiectoria cercetării din domeniul, de la atingerea acestei etape în 2012, ei bine, aceasta a fost susținută de o finanțare substanțială din partea organismelor guvernamentale, a instituțiilor academice și a *startup*-urilor. Afluxul de capital a declanșat un val de entuziasm pentru această ramură a cercetării în domeniul inteligenței artificiale, cunoscută sub numele de *Deep Learning*.

În vederea aprofundării modului de operare al acestor rețele neuronale poate fi folosită aplicația *DL* a *Google*, *Tensor Flow* [48]. În figura de mai jos se poate vedea o problemă *Deep Learning* tipică: punctele albastre și cele portocalii sunt reprezentări ale unui set de date ce cuprinde elemente distincte – un punct portocaliu ar putea simboliza *spam*, în timp ce un punct albastru ar semnifica *non-spam*, în mod similar, un punct portocaliu ar putea indica o postare ofensatoare, în timp ce un punct albastru semnifică o postare non-ofensatoare [49]; sau, urmând experimentul lui Andrew Ng, un punct portocaliu poate reprezenta o pisică într-un videoclip *YouTube*, în timp ce un punct albastru ar reprezenta un câine. Toate aceste categorii sunt reprezentate în imaginea de mai jos prin puncte. Rolul rețelei neuronale este de a separa aceste puncte prin utilizarea rețelelor neuronale.

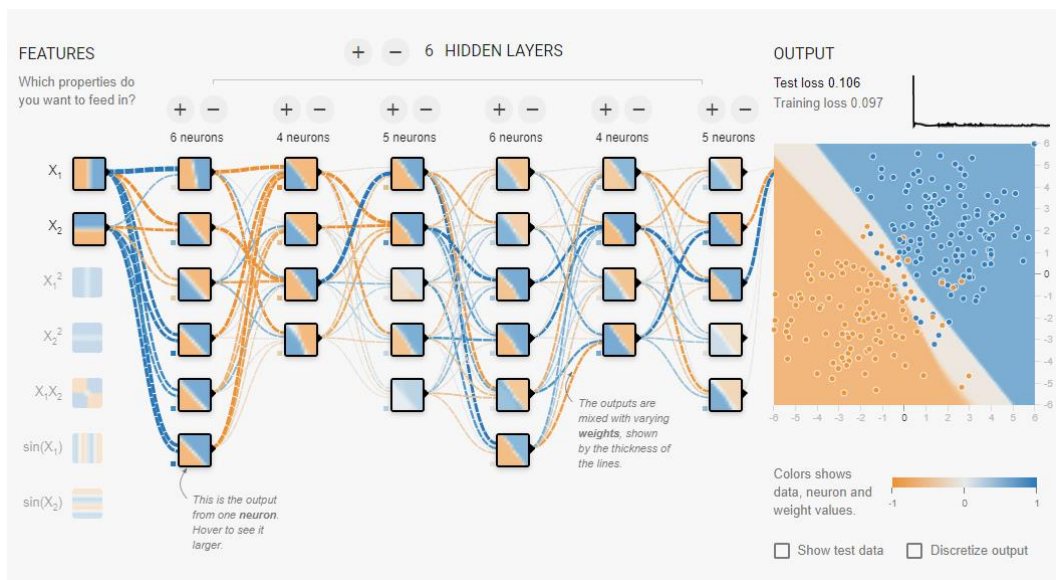


Fig. 3. Exemplu de lucru unei rețele neuronale folosind *TensorFlow*
 Source: <https://github.com/tensorflow/playground>

După introducerea datelor și construirea unei rețele neuronale, execuția acesteia reprezintă etapa finală. Rețelele de tip *Deep Learning* se caracterizează prin straturi multiple. În figura de mai sus, există evidențiate șase straturi, fiecare conținând propriul său set de neuroni. Incorporarea acestor neuroni duce la formarea de conexiuni între ei, ceea ce reprezintă aspectul fundamental al sistemului. Rețeaua neuronală se autoinstruiește, utilizând datele de intrare pentru a determina puterea conexiunilor dintre nodurile individuale. Nuanțele variabile ale liniilor albastre și portocalii, care interconectează toate nodurile (neuroni) din cadrul rețelei, corespund intensității acestor conexiuni.

În esență, rețelele neuronale ajustează valoarea conexiunilor ca răspuns la datele de intrare. Procesul de „învățare” este inițiat în virtutea capacității inerente a rețelei de a stabili interconexiuni ce, spre final, duc la detectarea și clasificarea punctelor. Odată cu furnizarea de date suplimentare, rețeaua se autoinstruiește rapid, reușind astfel să distingă în mod și mai eficient punctele albastre de cele portocalii. În mod remarcabil, în acest caz particular, doar treizeci de neuroni s-au dovedit a fi suficienți pentru ca rețeaua să delimiteze, cu un grad ridicat de precizie, limitele mulțimiilor.

Această demonstrație oferă o perspectivă valoroasă asupra mecanismelor operaționale ale acestor sisteme. De remarcat este că nu au fost transmise inițial sistemului obiective explicite; în mod independent, calculatorul a dobândit capacitatea de a ajusta ponderile conexiunilor dintre toate nodurile din cadrul rețelei, facilitând astfel discriminarea sa matematică între punctele albastre și portocalii.

Pentru a oferi o înțelegere contextuală, în figura descrisă mai sus este prezentat un număr modest de conexiuni – câteva zeci de sinapse, între nodurile rețelei. Dacă luăm în considerare experimentul *cat finder* – așa cum a fost el denumit mai târziu, al lui Andrew

Ng, caracterizat de un miliard de conexiuni [43], sau remarcabilul *GPT-4*, care se mândrește cu un număr impresionant de o sută de trilioane de conexiuni [50], amploarea fenomenului devine evidentă.

2. Tehnici și tehnologii AI

În articolele din *mass-media*, termenii *Inteligență Artificială*, *Machine Learning* și *Deep Learning* sunt adesea utilizați în mod interschimbabil, în ciuda diferențelor dintre ei. La nivel conceptual, *Machine Learning* cuprinde o gamă largă de metodologii menite să confere computerelor capacități cognitive asemănătoare celor umane. Acest domeniu extins cuprinde, de asemenea, diverse tehnici, inclusiv prelucrarea limbajului uman (*Natural Language Processing – NLP*), analiza sintactică, optimizarea căutării și sistemele expert, toate acestea încercând să simuleze comportamentul uman în cadrul sistemelor de calcul.

Machine Learning poate fi considerată ca un subset distinct în cadrul unui spectru mai larg de tehnici de calcul [30]. Ea se aliniază cu alte metodologii, cum ar fi tehnicile de căutare, de satisfacere a constrângerilor și a celor ce țin de raționamentul logic [51]. O examinare și mai atentă a *ML* scoate la suprafață o gamă diversă de tehnici, inclusiv *Deep Learning*, *Rule Learning*, *Decision Trees*, *Random Forests* și multe altele, toate acestea având rolul de a permite mașinilor să învețe din date [52, 53, 54, 49]. Dintre toate acestea, *Deep Learning* a apărut ca fiind cea mai importantă metodă din domeniul sistemelor de învățare automată, prezentând eficacitate și o precizie remarcabilă [55].

Informațiile de mai sus oferă o taxonomie cuprinzătoare a acestor cadre conceptuale, inteligența artificială cuprinzând o gamă variată de algoritmi și tehnici dedicate emulației inteligenței umane. În cadrul acestui domeniu amplu, *Machine Learning* constituie o abordare specifică, iar *Deep Learning* este una dintre tehnicile care intră în sfera de aplicare a *Machine Learning*.

Este imperativ să fie făcută diferența între reprezentările din *mass-media*, exemplificate de filme precum *Her*, *Chappie*, *Terminator* și multe altele care propun subiectul în diferite realizări artistice ale marilor case de producție. Astfel de reprezentări, în care mașinile au un comportament asemănător cu cel uman, se încadrează ferm în domeniul *SF (Science-Fiction)* și nu reflectă starea actuală a inteligenței artificiale.

Inteligența Artificială – ca domeniu specializat în cadrul științei informatice, cuprinde o serie de metodologii și tehnici specifice studiului său, iar *Deep Learning* a apărut ca fiind cea mai promițătoare și mai productivă abordare din ultimele decenii, având ca scop facilitarea dezvoltării de mașini capabile să reproducă comportamentul uman.

Machine Learning are aplicații omniprezente în diverse aspecte ale vieții de zi cu zi, ceea ce subliniază importanța sa pragmatică. Printre exemplele notabile se numără optimizarea titlurilor atractive de pe *BuzzFeed* [56] prin utilizarea tehnicilor de *Deep Learning*. Mai mult, pentru persoanele care își pun la dispoziție spațiile de cazare/locuire prin *Airbnb*, generarea prețurilor recomandate pentru anunțuri se bazează de asemenea pe metodologii *Deep Learning* [57]. Aplicația foto a *Android* utilizează algoritmi de recunoaștere facială,

care valorifică *Deep Learning*, pentru a organiza fotografiile în grupuri pe baza persoanelor [58]. În plus, *Deep Learning* alimentează funcționalitățile de căutare vizuală de pe *Pinterest*, permițând potrivirea preferințelor utilizatorilor [59]. În cazul *ChatGPT*, o parte substanțială a procesării limbajului natural, esențială pentru generarea de răspunsuri coerente, se bazează pe *Deep Learning* [60]. Prin urmare, fiecare dintre noi utilizează deja tehnici *ML* și *DL* în diverse situații, ca parte integrantă a rutinei noastre zilnice.

Având în vedere progresele înregistrate în domeniu, apar tot mai multe întrebări cu privire la amploarea potențialului său și la fezabilitatea realizării unei inteligențe umane așa cum o știm noi. Pentru a răspunde acestor întrebări, este prudent să revizuim obiectivele inițiale de proiectare a inteligenței artificiale.

Deep Learning, așa cum am menționat, a demonstrat deja progrese remarcabile în domeniul raționamentului uman în comparație cu toate tehnicile anterioare. *Mass-media* a evidențiat realizări precum victoria lui *AlphaGo* asupra unui mare maestru uman în jocul de *Go* [61]. Deși acest joc poate părea simplu la o primă vedere, fiind doar un joc de societate, complexitatea lui nu trebuie subestimată. Jocul de *Go*, pe o tablă standard (19x19), oferă mai multe mutări potențiale (10^{170} [62]) decât numărul de atomi din univers – estimat în mod obișnuit la 10^{82} [63]. *Go* este astfel semnificativ mai complex decât șahul – deja bine cunoscut atunci când se vorbește despre complexitate (și care are 10^{120} de mutări posibile [64], un număr cunoscut în lumea șahului și a matematicii sub numele de „numărul Shannon” – același Shannon care a participat la prima conferință de inteligență artificială de la *Dartmouth*, pe care am menționat-o la începutul articolului). Tehnicile tradiționale de inteligență artificială, cum ar fi căutarea prin *brute force* a tuturor posibilităților, devin inutile din cauza acestei enorme complexități, având în vedere că puterea de calcul disponibilă este, cel puțin deocamdată, absolut insuficientă pentru a explora toate mutările potențiale.

Prin urmare, aplicarea tehnicilor *Deep Learning* devine esențială pentru a determina ce ramuri ale arborelui de căutare trebuie investigate. În acest context, *DL* servește drept organizator principal al multiplelor tehnici utilizate pentru a stabili ce mutări ar trebui evaluate în cadrul jocului.

Transmisia în direct a jocurilor de *Go* cu *AlphaGo* a reaprins pasiunea pentru acest joc în rândul jucătorilor profesioniști și amatori din întreaga lume. Reacțiile la mutările neconvenționale efectuate de computer au fost de surpriză și intrigă, deoarece inteligența artificială a demonstrat strategii și tactici cu totul diferite de cele ale jucătorilor umani. Percepute inițial ca fiind decizii proaste, aceste mutări s-au dovedit în cele din urmă avantajoase, ducând la victoria lui *AlphaGo* cu scorul de 4 la 1 [65].

Acest fenomen a declanșat un *feedback* interesant în interacțiunea dintre oameni și mașini. Observarea inteligenței artificiale, în acest caz *AlphaGo*, rezolvând probleme asociate unui joc atât de complex precum cel de *Go*, influențează prin prezentarea de noi perspective și strategii. Acest lucru este exemplificat de comentariile făcute de marele maestru Lee Sedol – cel care s-a confruntat cu înfrângerea suferită în fața lui *AlphaGo*. El a recunoscut că interacțiunea sa cu *AI* i-a îmbunătățit semnificativ înțelegerea jocului, inspirându-i noi idei

și strategii [66]. Această observație subliniază dinamica potențială a interacțiunii dintre om și AI în contexte mai largi, sugerând o relație simbiotică în care ambele entități învață și evoluează una de la cealaltă.

În plus, influența profundă a lui *AlphaZero*, un motor de șah extrem de puternic creat de *Google DeepMind* [67], a lăsat o impresie de durată în lumea șahului. Merită subliniat aici faptul că Magnus Carlsen, fost campion mondial la șah și cunoscut ca fiind cel mai bun jucător de șah al prezentului [68], a recunoscut impactul transformator pe care acest motor revoluționar l-a exercitat asupra abordării sale strategice și asupra competenței sale ca jucător. Atunci când se analizează realizările remarcabile ale lui Carlsen pe parcursul ultimilor ani, rolul indispensabil jucat de *AlphaZero* în susținerea succeselor lui, devine un factor de netăgăduit și care necesită recunoaștere adecvată [69].

O altă mașină remarcabilă, cu rezultate pe măsură în materie de rezonare, este *GPT-4*, un model avansat de inteligență artificială dezvoltat de *OpenAI*, menționat anterior. Acesta a fost aclamat pentru realizările sale remarcabile într-o gamă diversă de examinări care acoperă mai multe domenii. Printre realizările notabile se numără o performanță excepțională în cadrul secțiunii de citire și scriere a testului de aptitudini școlare din Statele Unite (*Scholastic Aptitude Test – SAT*) – echivalentul examenului de bacalaureat, unde *GPT-4* a obținut un scor impresionant de 710 puncte dintr-un total de 800, situându-se în cadrul celui mai apreciat palier de scoruri. În mod similar, la secțiunea de matematică, *GPT-4* și-a demonstrat aptitudinile prin obținerea unui scor lăudabil de 700 de puncte din 800. Testul din semifinalele Olimpiadei de biologie din SUA a fost martorul competenței excepționale a *GPT-4*, care a obținut un scor extraordinar, cuprins între percentilele 99 și 100. În plus, *GPT-4* a demonstrat o competență remarcabilă la o gamă largă de examene *Advanced Placement (AP)*, inclusiv la materii precum *AP Art History*, *AP Biology* și *AP Environmental Science*, printre altele, obținând note foarte bune la aceste evaluări riguroase. În plus, *GPT-4* a demonstrat performanțe lăudabile la examenul de licență medicală din Statele Unite (*United States Medical Licensing Examination – USMLE*), depășind în mod constant pragurile de trecere stipulate la toate cele trei componente ale examenului [70]. Este important de remarcat faptul că, deși *GPT-4* a demonstrat competență, performanța sa a variat în cadrul diferitelor examene, indicând multe zone potențiale de perfecționare și îmbunătățire ulterioară care însă nu vor rămâne neacoperite prea mult timp de dezvoltatorii de la *OpenAI*, ceea ce indică evoluția dar și interesul tot mai crescut al tehnologiilor AI.

3. Direcții emergente în AI

3.1. Raționament

Mass-media, hrănită câteodată de efervescența rețelelor de socializare, publică articole ce sugerează că inteligența artificială va face ca oamenii să fie înlocuiți de mașini. Cu toate acestea, articolele științifice, precum cele citate în acest eseu dar și multe altele [71, 72, 73], susțin că aceasta nu îi va înlocui pe oameni, ci le va spori abilitățile, augmentându-le – un fenomen deja observabil în domeniul jocului de *Go* și de șah, după cum am menționat anterior.

Prin utilizarea acestor tehnici s-a reușit depășirea performanțelor umane în diverse sarcini complexe ce necesitau, în mod tradițional, o înțelegere a naturii lucrurilor din jur – a lumii (!!). Aceste sarcini se extind de la diagnosticarea medicală, cum ar fi identificarea bolilor, interpretarea razelor X pentru detectarea tumorilor, până la determinarea prezenței celulelor canceroase în probele de sânge [74] sau chiar la detectarea infecțiilor asimptomatice Covid-19 prin intermediul tusei înregistrate de telefonul mobil [75]. Aceste sarcini erau de obicei îndeplinite de profesioniști cu o înaltă pregătire.

Punctul forte al tehnologiilor *Deep Learning* constă în capacitatea acestora de a procesa cantități mari de date, permițând astfel identificarea și clasificarea diferitelor elemente – de exemplu, determinarea dacă o probă de sânge conține sau nu celule canceroase. Acest progres este o ilustrare clară a modului în care *DL* poate obține performanțe superioare în comparație cu eforturile umane în anumite domenii.

Anticipăm că un număr din ce în ce mai mare de *startup*-uri vor valorifica aceste capacități, obținând performanțe mai bune decât cele umane în domenii despre care odată se credea că țin de competența exclusivă a persoanelor cu o pregătire superioară. Astfel, mai degrabă decât să înlocuiască oamenii, inteligența artificială, și în special tehnologiile *Deep Learning*, vor spori abilitățile și performanțele umane [76].

3.2. Planificare și navigare

Având în vedere subiectul planificării și navigației, este demn de remarcat aici povestea lui George Hotz, *CEO* al companiei *COMMA.AI*. În mod remarcabil, Hotz a reușit să construiască de unul singur o mașină care se conduce singură [77, 78].

Pentru a pune reușita lui în context, trebuie menționat că primul *Grand Challenge* în domeniul *self-driving cars*, a avut loc în anul 2004 în deșertul *Mojave* din California [79] și a fost sponsorizat de *DARPA* (*Defense Advanced Research Projects Agency*) din Statele Unite. Competiția a atras douăzeci de participanți de la universități și *startup*-uri de top, toți concurând pentru a parcurge un traseu de 241 de kilometri (150 mile) în deșert. Cea mai bună performanță a fost obținută de *Sandstorm*, o mașină cu conducere autonomă construită de echipa a universității *Carnegie Mellon* din *Pittsburgh, Pennsylvania*, care a reușit să parcurgă mai puțin de 12 kilometri (7,32 mile) din traseul total.

Trei ani mai târziu, în 2007, *DARPA* a sponsorizat *Urban Challenge* [80], un traseu urban de 96 de kilometri (60 mile) stabilit la baza aeriană *George Air Force Base* din California. În cadrul acestei provocări, automobilele mai multor universități au reușit să termine traseul, *Carnegie Mellon* și *Stanford* ocupând primele locuri. Această evoluție, de la incapacitatea de a parcurge mai mult de 12 kilometri în deșert, la finalizarea unui traseu urban de aproape 100 de kilometri, a declanșat o cursă spre dezvoltarea aplicațiilor *self-driving cars* [81].

În prezent, toți marii producători de automobile finanțează masiv dezvoltarea din domeniul conducerii autonome. Printre aceste companii se numără giganți precum *General Motors*, *Ford*, *Tesla*, *Google*, *Toyota*, *Lyft*, *Uber*, *Bosh*, *Volkswagen* și multe altele [82, 83].

În acest context, reușita lui Hotz de a construi o mașină care se conduce singură, complet funcțională, folosind tehnici *Deep Learning* și bazându-se exclusiv pe resurse *open-source*, este cu adevărat uimitoare. Acest caz evidențiază potențialul extraordinar al tehnologiilor *DL*. Sofisticarea acestor algoritmi *open-source* a ajuns la un punct în care o persoană poate construi o mașină care se conduce singură, o sarcină care, în mod tradițional, necesita eforturile a mii de ingineri din centrele de cercetare și dezvoltare ale companiilor. Putem anticipa din nou un interes în dezvoltarea *startup*-urilor ce vizează folosirea tehnologiilor *DL*, de data asta în vederea dezvoltării aplicațiilor pentru mașini autonome.

Astăzi, *Waymo*, compania de vehicule autonome deținută de *Alphabet* (compania-mamă a *Google*), a început să ofere servicii de taxi fără șofer în *San Francisco* [84]. Nu sunt singurii! *Cruise* – marcă a *General Motors*, sunt de asemenea prezenți pe piață [85], ceea ce a făcut ca autoritățile să aprobe de curând – 10 august 2023, operarea 24/7 a taxiurilor fără șofer în *San Francisco* [86, 87].

3.3. Procesarea limbajului natural

După cum am menționat încă de la începutul prezentului articol, domeniul înțelegerii limbajului natural (*Natural Language Processing – NLP*) este unul dintre primele domenii de explorare în inteligența artificială. Cu toate acestea, progrese semnificative realizate de la acele experimente inițiale, abia au început să apară, *NLP* rămânând o problemă extrem de complexă. Combinația dintre *Deep Learning* și uriașa cantitate de date disponibile în prezent pe *web*, cum ar fi fluxurile *Twitter*, postările pe *Facebook* alături de cele de pe *Wikipedia* și blogurile nenumăraților utilizatori de Internet, oferă o sursă solidă pentru a alimenta aceste sisteme în încercarea de a efectua sarcini complexe din zona de cercetare/dezvoltare a *NLP*.

Un exemplu, poate extrem, al complexității limbajului vorbit este propoziția *„Buffalo buffalo Buffalo buffalo buffalo buffalo Buffalo buffalo.”* care, evident, reprezintă o provocare în ceea ce privește înțelegerea contextului și a părților de vorbire. Poate merită menționat aici că această propoziție, în particular, are chiar și o pagină proprie pe *Wikipedia* [88] ea fiind una perfect valabilă în limba engleză din punct de vedere gramatical.

Învățarea profundă contribuie în mod semnificativ la abordarea acestor provocări. *Google*, de exemplu, a lansat un proiect *open-source* care vizează identificarea părților unei propoziții, împărțind-o în substantive, verbe, attribute, complemente și așa mai departe. Acest proiect, cunoscut sub numele de *robots.txt parser*, ilustrează și mai mult progresele făcute în domeniul *NLP* [89].

GPT-4 de la *OpenAI* atrage deja multă atenție, *Bard*, a celor de la *Google* este și ea o aplicație deosebit de puternică din zona *NLP* ce folosește *Large Language Models (LLMs)* ca bază de lucru pentru tehnologii *Deep Learning* ce au rolul de a procesa cantități uriașe de text culese de pe Internet... iar competiția se află abia la început. Mai merită menționată aici aplicația *LLaMA* a celor de la *Meta/Facebook* și *Claude* dezvoltată de *Anthropic* (un *startup*), și acestea cu abilități de înțelegere și generare a textului aproape umane după cum spune Blake Lemoine, un fost inginer *Google* care a mers chiar mai departe cu afirmația zicând că *„LaMDA* [un alt *software NLP* dezvoltat de *Google*] prezintă semne de

conștiință” [90]. Gigantul *Microsoft* a testat la rândul său *GPT-4* ajungând la concluzia că, în unele situații, aplicația celor de la *OpenAI* excede abilitățile umane de a înțelege și genera text [91, 92]).

3.4. Percepție




Fig. 4. Viziune computerizată pentru mașinile care se conduc singure

Source: <https://enercopower.com/>

În domeniul percepției se fac de asemenea progrese semnificative datorate în mare parte tehnologiilor *Deep Learning*. Dacă ar fi continuăm cu exemplul unui vehicul autonom, așa cum am vorbit în una din secțiunile precedente, și abilitatea acestuia de a analiza o scenă stradală ca cea din figura 4, acesta trebuie să identifice diverse elemente precum: un sedan în față (care se deplasează cu aproximativ 5,4 km/h), pe partea dreaptă alte două (staționare), în stânga un automobil în mișcare ce se deplasează cu viteza de 3,6 km/h precum și obiecte staționare, cum ar fi stâlpi și semafoare. Sistemul trebuie să fie capabil să clasifice toate aceste obiecte în timp real, să facă predicții cu privire la pozițiile lor viitoare și să planifice în consecință un traseu sigur și eficient. Tehnologiile *DL* joacă un rol esențial în dezvoltarea abilităților vehiculelor autonome de a interpreta și analiza astfel de scene.

Tot despre percepție este și experiențitul *cat finder* a profesorului Andrew Ng de la *Stanford*, despre care am vorbit mai sus.

Impactul acestor tehnologii se extinde și în lumea afacerilor, după cum o demonstrează creșterea și succesul recent al *Nvidia* – merită menționat aici faptul că *Nvidia* este astăzi a VI-a cea mai mare companie de pe planetă cu o capitalizare bursieră de 1,125 trilioane de dolari [93]. Această companie a atribuit o parte semnificativă a progresului său noii sale linii de afaceri, care oferă sisteme *DL* pentru vehicule autonome. *CEO*-ul și cofondatorul *Nvidia*, Jensen Huang, a declarat cu ocazia conferinței *GTC Developer Conference* din martie 2023 – eveniment ce a marcat cei treizeci de ani de existență a companiei, că „accelerarea creșterii afacerii noastre este reprezentată de *Deep Learning*, un nou model de

calcul care utilizează puterea de calcul masivă a *GPU*-urilor pentru a instrui algoritmi de inteligență artificială. Adoptarea sa se răspândește din industrie în industrie, stimulând cererea pentru *GPU*-urile noastre” [94]. După cum reiese din această declarație, influența *Deep Learning* este deosebit de vastă, având un impact puternic asupra diferitelor aspecte ale sectorului tehnologic, de la cipurile de siliciu utilizate în construcția componentelor *hardware* la aplicațiile *software* destinate să lucreze pe acestea.

3.5. *AGI – Artificial General Intelligence*

Perspectiva interesantă pe care o au tehnologiile *Deep Learning* este că acestea ne propulsează spre realizarea unor progrese semnificative în toate obiectivele fundamentale ale inteligenței artificiale, mai exact cele care au în vedere emularea diverselor aspecte ale comportamentului uman. Acest lucru ar putea semnala, potențial, calea către *AGI*, care să cuprindă fațete precum inteligența emoțională, creativitate și intuiție. Într-adevăr, un domeniu în plină expansiune al cercetării în domeniul *AI*, și cu precădere *DL*, se concentrează pe creativitate, cu proiecte precum *Deep Jazz* – care poate produce compoziții de jazz inedite (interesant este faptul că acest proiect a fost construit în 36 de ore în cadrul unui *hackathon*) [95], *Dall-e* – excelent pentru generarea de imagini [96] și multe altele pe care le lăsăm cititorilor să le descopere.

Acest lucru ar putea fi perceput ca fiind începutul unui progres transformator în cercetarea în domeniul inteligenței artificiale. Perspectiva dominantă este că orice aplicație serioasă necesită de acum înainte încorporarea tehnologiilor *AI*, la fel cum cipurile *Intel* au fost cruciale pentru toate sistemele de calcul serioase, fapt subliniat de campania de marketing *Intel Inside a Intel* [97]. La fel se poate preconiza că *Deep Learning* va fi parte integrantă a sistemelor viitoare, sporindu-le viteza, capacitatea de reacție și ușurința de utilizare permițându-ne astfel să anticipăm că aceste tehnologii vor fi o caracteristică de bază a tuturor aplicațiilor care vor fi dezvoltate în viitor.

4. Concluzie

În prezent, ne aflăm într-o primăvară a inteligenței artificiale și numai timpul ne va arăta dacă aceasta va duce la realizarea unei inteligențe generalizate (*AGI*). Cu toate acestea, ceea ce este în general acceptat și de necontestat este faptul că *Deep Learning* reprezintă cel mai important progres în cercetarea în domeniul inteligenței artificiale de la începutul acesteia din vara anului 1956. Această tehnologie va spori eficiența, inteligența și capacitatea de reacție a fiecărei aplicații, iar mișcările mediului de *business* din jurul *startup*-urilor din domeniul *IT/AI* par a fi vârful de lance al tuturor acestor inițiative. Prin urmare putem spune că am pășit într-o eră entuziasmantă fiind îndreptățiți să credem că *AI* și *Deep Learning* ar putea reprezenta schimbări tehnologice precum cele aduse de tehnologiile mobile și *cloud* în ultimii cinci, zece ani.

Notă

Este important de menționat faptul că unele secțiuni ale acestui articol vor fi incluse într-o publicație viitoare intitulată "AI de la idee la implementare". Această publicație încrucișată își propune să disemineze rezultatele cercetării către un public academic mai larg și să contribuie la discursul în evoluție privind rolul inteligenței artificiale în societatea actuală.

References

- [1] Bloomberg, *Google CEO Sees AI as More Profound Than Fire, Electricity*, 2020.
- [2] Meta, „Update on Meta’s Year of Efficiency,” Meta, 14 3 2023. [Interactiv]. Available: <https://about.fb.com/news/2023/03/mark-zuckerberg-meta-year-of-efficiency/>. [Accesat 13 5 2023].
- [3] B. Gates, „The Age of AI has begun,” 21 3 2023. [Interactiv]. Available: <https://www.gatesnotes.com/The-Age-of-AI-Has-Begun>. [Accesat 13 5 2023].
- [4] Alphabet, „This year’s Founders’ Letter,” Alphabet, 28 4 2016. [Interactiv]. Available: <https://blog.google/alphabet/this-years-founders-letter/>. [Accesat 13 5 2023].
- [5] Cantor’s Paradise, „The Birthplace of AI. The 1956 Dartmouth Workshop,” Cantor’s Paradise, 12 9 2019. [Interactiv]. Available: <https://www.cantorsparadise.com/the-birthplace-of-ai-9ab7d4e5fb00>. [Accesat 13 5 2023].
- [6] Theoi.com, „<https://www.theoi.com/Ther/Automotones.html>,” Theoi Project, [Interactiv]. Available: <https://www.theoi.com/Ther/Automotones.html>. [Accesat 14 5 2023].
- [7] N. Sharkey, „The programmable robot of ancient Greece,” *NewScientist*, 4 7 2007. [Interactiv]. Available: <https://www.newscientist.com/article/mg19526111-600-the-programmable-robot-of-ancient-greece/>. [Accesat 14 5 2023].
- [8] G. Maspero, *Manual of Egyptian Archaeology and Guide to the Study of Antiquities in Egypt*, Cambridge University Press, 2012.
- [9] M. Shelley, *Frankenstein; or, The Modern Prometheus*, United Kingdom: Lackington, 1818.
- [10] V. Jayanti, Regizor, *Game Over Kasparov and the Machine*. [Film]. US/Canada: Alliance Atlantis & National Film Board of Canada, 2003.
- [11] G. Kasparov, „Chess, a Drosophila of reasoning,” 7 12 2018. [Interactiv]. Available: <https://www.science.org/doi/10.1126/science.aaw2221#:~:text=Much%20as%20the%20Drosophila%20melanogaster,unlock%20secrets%20of%20human%20thought..> [Accesat 29 06 2023].
- [12] J. McCarthy, „Chess as the Drosophila of AI,” *Computers, Chess, and Cognition*, 1990.
- [13] TechTarget, „Lisp (programming language),” TechTarget, [Interactiv]. Available: <https://www.techtarget.com/whatis/definition/LISP-list-processing>. [Accesat 14 5 2023].
- [14] SRI International, „Shakey the Robot,” SRI International, [Interactiv]. Available: <https://www.sri.com/hoi/shakey-the-robot/>. [Accesat 17 5 2023].
- [15] IBM, „Speaking out loud. An introduction to natural language processing,” IBM, 12 6 2017. [Interactiv]. Available: <https://developer.ibm.com/articles/cc-cognitive-natural-language-processing/>. [Accesat 17 5 2023].
- [16] H. Knight, „Early Artificial Intelligence Projects,” *CSAIL @ MIT*, 8 2006. [Interactiv]. Available: <https://projects.csail.mit.edu/films/aifilms/AIFilms.html>. [Accesat 17 5 2023].
- [17] S. Schuchmann, „History of the first AI Winter,” *Medium*, 12 5 2019. [Interactiv]. Available: <https://towardsdatascience.com/history-of-the-first-ai-winter-6f8c2186f80b>. [Accesat 19 5 2023].
- [18] T. Poibeau, *Machine Translation*, Cambridge: MIT Press, 2017.
- [19] J. Hutchins, „MT News International,” 14 6 1996. [Interactiv]. Available: <https://aclanthology.org/www.mt-archive.info/90/MTNI-1996-Hutchins.pdf>. [Accesat 19 5 2023].
- [20] D. M. Berry, Weizenbaum, *ELIZA and the end of human reason*, Berlin, 2018.
- [21] NJIT, „ELIZA: a very basic Rogerian psychotherapist chatbot,” *New Jersey Institute of Technology*, [Interactiv]. Available: <https://web.njit.edu/~ronkowitz/eliza.html>. [Accesat 19 5 2023].
- [22] S. Schuchmann, „Medium,” *History of the Second AI Winter*, 12 5 2019. [Interactiv]. Available: <https://towardsdatascience.com/history-of-the-second-ai-winter-406f18789d45>. [Accesat 19 5 2023].
- [23] Forbes, „History Of AI In 33 Breakthroughs: The First Expert System,” *Forbes*, 29 10 2022. [Interactiv]. Available: <https://www.forbes.com/sites/gilpress/2022/10/29/history-of-ai-in-33-breakthroughs-the-first-expert-system/?sh=66e5f29b4f86>. [Accesat 19 5 2023].

- [24] Britannica, „DENDRAL expert system,” Britannica, [Interactiv]. Available: <https://www.britannica.com/technology/DENDRAL>. [Accesat 5 19 2023].
- [25] W. v. Melle, „MYCIN: a knowledge-based consultation program for infectious disease diagnosis,” *International Journal of Man-Machine Studies*, vol. 10, nr. 3, pp. 313-322, 1978.
- [26] D. Weinreb, „History of Symbolics lisp machines,” [Interactiv]. Available: <https://danluu.com/symbolics-lisp-machines/>. [Accesat 19 5 2023].
- [27] A. Graylin, K. A. H. Kjölaas, J. Loflin și J. D. W. III, „Symbolics, Inc.: A failure of heterogeneous engineering,” [Interactiv]. Available: <https://www.ifis.uni-luebeck.de/~moeller/symbolics-info/Symbolics.pdf>. [Accesat 19 5 2023].
- [28] University of Washington, „The History of Artificial Intelligence,” 12 2006. [Interactiv]. Available: <https://courses.cs.washington.edu/courses/csep590/06au/projects/history-ai.pdf>. [Accesat 19 5 2023].
- [29] IBM, „What is deep learning?,” IBM, [Interactiv]. Available: <https://www.ibm.com/topics/deep-learning>. [Accesat 19 5 2023].
- [30] C. Vrabie, „Artificial Intelligence Promises to Public Organizations and Smart Cities,” *Digital Transformation. Lecture Notes in Business Information Processing*, vol. 465, 8 12 2022.
- [31] A. L. Chandra, „McCulloch-Pitts Neuron — Mankind’s First Mathematical Model Of A Biological Neuron,” Medium, 24 7 2018. [Interactiv]. Available: <https://towardsdatascience.com/mcculloch-pitts-model-5fdf65ac5dd1>. [Accesat 19 5 2023].
- [32] L. Hardesty, „Explained: Neural networks,” MIT News Office, 14 4 2017. [Interactiv]. Available: <https://news.mit.edu/2017/explained-neural-networks-deep-learning-0414>. [Accesat 19 5 2023].
- [33] IBM, „What are neural networks?,” IBM, [Interactiv]. Available: <https://www.ibm.com/topics/neural-networks>. [Accesat 19 5 2023].
- [34] Amazon, „What Is A Neural Network?,” Amazon, [Interactiv]. Available: <https://aws.amazon.com/what-is/neural-network/>. [Accesat 19 5 2023].
- [35] DataBricks, „Neural Network,” DataBricks, [Interactiv]. Available: <https://www.databricks.com/glossary/neural-network>. [Accesat 19 5 2023].
- [36] C. Vrabie, *Elemente de E-Guvernare [Elements of e-government]*, Bucharest: Pro Universitaria, 2016.
- [37] Y. Lecun, B. Boser, J. S. Denker, D. Henderson, R. E. Howard, W. Hubbard și L. Jackel, „Backpropagation applied to handwritten zip code recognition,” *Computer Science*, vol. 1, nr. 4, pp. 541-551, 1989.
- [38] O. Matan, H. Baird, J. Bromley, C. Burges, J. Denker, L. Jackel, Y. L. Cun, E. Pednault, W. Satterfield și C. Stenard, „Reading handwritten digits: a ZIP code recognition system,” *Computer*, vol. 25, nr. 7, pp. 59-63, 1992.
- [39] G. E. Hinton, „Deep belief networks,” Scholarpedia , [Interactiv]. Available: http://www.scholarpedia.org/article/Deep_belief_networks. [Accesat 20 5 2023].
- [40] Association for Computing Machinery, „Bengio, Hinton and LeCun Ushered in Major Breakthroughs in Artificial Intelligence,” ACM, 2018. [Interactiv]. Available: <https://awards.acm.org/about/2018-turing>. [Accesat 20 5 2023].
- [41] S. Hochreiter și J. Schmidhuber, „Long Short-Term Memory,” *Neural Computation*, vol. 9, nr. 8, p. 1735–1780., 1997.
- [42] V. Choubey, „Understanding Recurrent Neural Network (RNN) and Long Short Term Memory (LSTM),” Medium, 23 7 2020. [Interactiv]. Available: <https://medium.com/analytics-vidhya/undstanding-recurrent-neural-network-rnn-and-long-short-term-memory-lstm-30bc1221e80d>. [Accesat 20 5 2023].
- [43] Q. V. Le, M. Ranzato, R. Monga, M. Devin, K. Chen, G. S. Corrado, J. Dean și A. Y. Ng, „Building High-level Features Using Large Scale Unsupervised Learning,” în *Proceedings of the 29 th International Conference on Machine Learning*, Edinburgh, 2012.
- [44] A. N. Jeff Dean, „Using large-scale brain simulations for machine learning and A.I.,” Google, 26 6 2012. [Interactiv]. Available: <https://blog.google/technology/ai/using-large-scale-brain-simulations-for/>. [Accesat 20 5 2023].

- [45] The New York Times, „How Many Computers to Identify a Cat? 16,000,” The New York Times, 25 6 2012. [Interactiv]. Available: <https://www.nytimes.com/2012/06/26/technology/in-a-big-network-of-computers-evidence-of-machine-learning.html>. [Accesat 20 5 2023].
- [46] NPR, „A Massive Google Network Learns To Identify — Cats,” NPR, 26 6 2012. [Interactiv]. Available: <https://www.npr.org/2012/06/26/155792609/a-massive-google-network-learns-to-identify>. [Accesat 20 5 2023].
- [47] The Sydney Morning Herald, „Google's 'brain simulator': 16,000 computers to identify a cat,” The Sydney Morning Herald, 26 6 2012. [Interactiv]. Available: <https://www.smh.com.au/technology/googles-brain-simulator-16000-computers-to-identify-a-cat-20120626-20zmd.html>. [Accesat 20 5 2023].
- [48] Tensor Flow, „Deep playground,” Tensor Flow, [Interactiv]. Available: <https://github.com/tensorflow/playground>. [Accesat 19 3 2023].
- [49] C. Vrabie, „E-Government 3.0: An AI Model to Use for Enhanced Local Democracies,” *Sustainability*, 2023.
- [50] WeStarter, „GPT-4 Parameters: 100 Trillion Steps to AI Mastery,” WeStarter, 4 4 2023. [Interactiv]. Available: <https://www.westarter.org/gpt-4-parameters/>. [Accesat 14 5 2023].
- [51] T. Malone, Interviewee, *Professor*. [Interviu]. May 2021.
- [52] M. Lewis, Y. Liu, N. Goyal, M. Ghazvininejad, A. Mohamed, O. Levy, V. Stoyanov și L. Zettlemoyer, „BART: Denoising Sequence-to-Sequence Pre-training for Natural Language Generation, Translation, and Comprehension,” 2019.
- [53] J. Devlin, M.-W. Chang, K. Lee și K. Toutanova, „BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding,” 2019.
- [54] A. Dosovitskiy, L. Beyer, A. Kolesnikov, D. Weissenborn, X. Zhai, T. Unterthiner, M. Dehghani, M. Minderer, G. Heigold, S. Gelly, J. Uszkoreit și N. Houlsby, „An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale”.
- [55] R. Balestriero, M. Ibrahim, V. Sobal, A. Morcos, S. Shekhar, T. Goldstein, F. Bordes, A. Bardes, G. Mialon, Y. Tian, A. Schwarzschild, A. G. Wilson, J. Geiping, Q. Garrido, P. Fernandez și A. Bar, „A Cookbook of Self-Supervised Learning”.
- [56] BuzzFeed, „BuzzFeed,” BuzzFeed, [Interactiv]. Available: <https://www.buzzfeed.com>. [Accesat 25 5 2023].
- [57] Emerd, „Artificial Intelligence at Airbnb – Two Unique Use-Cases,” 4 10 2021. [Interactiv]. Available: <https://emerj.com/ai-sector-overviews/artificial-intelligence-at-airbnb/>. [Accesat 25 5 2023].
- [58] Google, „Magic Editor in Google Photos: New AI editing features for reimagining your photos,” Google, 10 3 2023. [Interactiv]. Available: <https://blog.google/products/photos/google-photos-magic-editor-pixel-io-2023/>. [Accesat 23 5 2023].
- [59] Wired, „How Pinterest Uses AI to Capture Our Imaginations,” Wired, [Interactiv]. Available: <https://www.wired.com/brandlab/2018/11/pinterest-uses-ai-capture-imaginations/>. [Accesat 25 5 2023].
- [60] DigitalTrends, „ChatGPT: How to use the AI chatbot that’s changing everything,” DigitalTrends, 19 5 2023. [Interactiv]. Available: <https://www.digitaltrends.com/computing/how-to-use-openai-chatgpt-text-generation-chatbot/>. [Accesat 25 5 2023].
- [61] Google DeepMind, „The Challenge Match,” AlphaGo, 2016. [Interactiv]. Available: <https://www.deepmind.com/research/highlighted-research/alphago/the-challenge-match>. [Accesat 25 5 2023].
- [62] Sensei's Library, „Number of Possible Go Games,” [Interactiv]. Available: <https://senseis.xmp.net/?NumberOfPossibleGoGames>. [Accesat 25 5 2023].
- [63] H. Baker, „How many atoms are in the observable universe?,” Live Science, 10 6 2021. [Interactiv]. Available: <https://www.livescience.com/how-many-atoms-in-universe.html>. [Accesat 25 5 2023].
- [64] The Chess Journal, „Shannon Number: What is the Shannon Number in Chess?,” [Interactiv]. Available: <https://www.chessjournal.com/shannon-number/>. [Accesat 25 5 2023].

- [65] D. Estrada, „Move 37!! Lee Sedol vs AlphaGo Match 2,” 12 3 2016. [Interactiv]. Available: https://www.youtube.com/watch?v=JNrXgpSEEIE&ab_channel=DanielEstrada.
- [66] Wired, „In Two Moves, AlphaGo and Lee Sedol Redefined the Future,” Wired, 16 3 2016. [Interactiv]. Available: <https://www.wired.com/2016/03/two-moves-alphago-lee-sedol-redefined-future/>. [Accesat 25 5 2023].
- [67] Google DeepMind, „AlphaZero: Shedding new light on chess, shogi, and Go,” Google, 6 12 2019. [Interactiv]. Available: <https://www.deepmind.com/blog/alphazero-shedding-new-light-on-chess-shogi-and-go>. [Accesat 25 5 2023].
- [68] International Chess Federation, „Top 100 Players May 2023,” FIDE, 5 2023. [Interactiv]. Available: <https://ratings.fide.com/>. [Accesat 25 5 2023].
- [69] New in chess, „The exciting impact of a game changer When Magnus met AlphaZero,” [Interactiv]. Available: https://www.newinchess.com/media/wysiwyg/product_pdf/872.pdf. [Accesat 25 5 2023].
- [70] Business Insider, „AI models like ChatGPT and GPT-4 are acing everything from the bar exam to AP Biology. Here's a list of difficult exams both AI versions have passed,” 21 3 2023. [Interactiv]. Available: <https://www.businessinsider.com/list-here-are-the-exams-chatgpt-has-passed-so-far-2023-1?r=US&IR=T>. [Accesat 25 5 2023].
- [71] C. SCHACHTNER, „Smart government in local adoption – Authorities in strategic change through AI,” *Smart Cities and Regional Development (SCRD) Journal*, vol. 5, nr. 3, pp. 53-61, 2021.
- [72] M. ROMANELLI, „Rediscovering urban intelligence within cities by technologies,” *Smart Cities and Regional Development (SCRD) Journal*, vol. 5, nr. 3, pp. 115-122, 2021.
- [73] K. Z. (Male), „Exchange rate forecasting with Artificial Intelligence,” *Smart Cities and Regional Development (SCRD) Journal*, vol. 7, nr. 1, pp. 65-70, 2023.
- [74] „The rise of artificial intelligence in healthcare applications,” *Artificial Intelligence in Healthcare*, pp. 25-60, 2020.
- [75] J. Chu, „Artificial intelligence model detects asymptomatic Covid-19 infections through cellphone-recorded coughs,” MIT News Office, 29 10 2020. [Interactiv]. Available: <https://news.mit.edu/2020/covid-19-cough-cellphone-detection-1029#:~:text=The%20model%20identified%2098.5%20percent,re%20asymptomatic%2C%E2%80%9D%20Subirana%20says..> [Accesat 25 5 2023].
- [76] McKinsey Global Institute, „Applying artificial intelligence for social good,” McKinsey & Co, 28 11 2018. [Interactiv]. Available: <https://www.mckinsey.com/featured-insights/artificial-intelligence/applying-artificial-intelligence-for-social-good>. [Accesat 25 5 2023].
- [77] Boston.com, „26-year-old single-handedly builds semi-autonomous car to rival Tesla's,” Boston.com, 17 12 2015. [Interactiv]. Available: <https://www.boston.com/cars/news-and-reviews/2015/12/17/26-year-old-single-handedly-builds-semi-autonomous-car-to-rival-teslas/>. [Accesat 25 5 2023].
- [78] The Verge, „On the road with George Hotz's \$1,000 self-driving car kit,” The Verge, 6 2016. [Interactiv]. Available: <https://www.theverge.com/2016/6/6/11866868/comma-ai-george-hotz-interview-self-driving-cars>. [Accesat 25 5 2023].
- [79] DARPA, „The Grand Challenge,” DARPA, 1 3 2004. [Interactiv]. Available: <https://www.darpa.mil/about-us/timeline/-grand-challenge-for-autonomous-vehicles>. [Accesat 25 5 2023].
- [80] DARPA, „DARPA Urban Challenge,” DARPA, 3 11 2007. [Interactiv]. Available: <https://www.darpa.mil/about-us/timeline/darpa-urban-challenge>. [Accesat 25 5 2023].
- [81] DARPA, „The DARPA Grand Challenge: Ten Years Later,” DARPA, 13 3 2014. [Interactiv]. Available: <https://www.darpa.mil/news-events/2014-03-13>. [Accesat 25 5 2023].
- [82] U.S. News, „Top 7 Autonomous Vehicle Stocks to Buy Now,” U.S. News, 23 4 2023. [Interactiv]. Available: <https://money.usnews.com/investing/stock-market-news/slideshows/top-autonomous-vehicle-stocks-to-buy-now>. [Accesat 25 5 2023].

- [83] Investors.com, „Automotive Industry News, Self-Driving Cars And Stocks To Watch,” Investors.com, 25 5 2023. [Interactiv]. Available: <https://www.investors.com/news/automotive-industry-news-self-driving-cars-and-stocks-to-watch/>. [Accesat 25 5 2023].
- [84] Waymo, „Meet Waymo One. Designed with SF at heart.,” Waymo, 2023. [Interactiv]. Available: <https://waymo.com/waymo-one-san-francisco/>. [Accesat 13 09 2023].
- [85] Cruise, „Driverless is here,” Cruise, 2023. [Interactiv]. Available: <https://getcruise.com/>. [Accesat 13 09 2023].
- [86] CNN Business, „Regulators give green light to driverless taxis in San Francisco,” 11 08 2023. [Interactiv]. Available: <https://www.cnn.com/2023/08/11/tech/robotaxi-vote-san-francisco/index.html>. [Accesat 13 09 2023].
- [87] The Washington Post, „California just opened the floodgates for self-driving cars,” The Washington Post, 10 08 2023. [Interactiv]. Available: <https://www.washingtonpost.com/technology/2023/08/10/san-francisco-robotaxi-approved-waymo-cruise/>. [Accesat 13 09 2023].
- [88] Wikipedia, „Buffalo buffalo Buffalo buffalo buffalo buffalo Buffalo buffalo,” Wikipedia, [Interactiv]. Available: https://en.wikipedia.org/wiki/Buffalo_buffalo_Buffalo_buffalo_buffalo_buffalo_Buffalo_buffalo. [Accesat 25 5 2023].
- [89] Google, „Google's robots.txt parser is now open source,” Google, 1 7 2019. [Interactiv]. Available: <https://developers.google.com/search/blog/2019/07/repp-oss>. [Accesat 26 5 2023].
- [90] The Washington Post, „The Google engineer who thinks the company’s AI has come to life,” The Washington Post, 11 06 2022. [Interactiv]. Available: <https://www.washingtonpost.com/technology/2022/06/11/google-ai-lamda-blake-lemoine/>. [Accesat 14 09 2023].
- [91] NewScientist, „Is GPT-4 already showing signs of artificial general intelligence?,” NewScientist, 24 03 2023. [Interactiv]. Available: <https://www.newscientist.com/article/2365864-is-gpt-4-already-showing-signs-of-artificial-general-intelligence/>. [Accesat 14 09 2023].
- [92] Microsoft, „Sparks of Artificial General Intelligence: Early experiments with GPT-4,” Microsoft, 03 2023. [Interactiv]. Available: <https://www.microsoft.com/en-us/research/publication/sparks-of-artificial-general-intelligence-early-experiments-with-gpt-4/>. [Accesat 14 09 2023].
- [93] Forbes, „Top 10 biggest companies in the world by market cap in 2023,” Forbes, 11 09 2023. [Interactiv]. Available: <https://www.forbesindia.com/article/explainers/top-10-largest-companies-world-market-cap/86341/1>. [Accesat 14 09 2023].
- [94] J. Huang, Interviewee, *GTC 2023 Keynote*. [Interviu]. 21 03 2023.
- [95] J.-S. Kim, „Using Keras & Theano for deep learning driven jazz generation,” [Interactiv]. Available: <https://deepjazz.io/>. [Accesat 26 5 2023].
- [96] OpenAI, „DALL·E 2 is an AI system that can create realistic images and art from a description in natural language.,” OpenAI, [Interactiv]. Available: <https://openai.com/product/dall-e-2>. [Accesat 26 5 2023].
- [97] Business Insider, „Inside the 'Inside Intel' Campaign,” 21 9 2009. [Interactiv]. Available: <https://www.businessinsider.com/inside-the-inside-intel-campaign-2009-9>. [Accesat 26 5 2023].