



Academia Oamenilor de Știință din România

RAPORT DE CERCETARE NR. 2 / 2022

**UTILIZAREA INTELIGENȚEI ARTIFICIALE
PENTRU OBȚINEREA SUPERIORITĂȚII COGNITIVE
ÎN ACȚIUNEA MILITARĂ**

Domeniul 28 - Tehnologii emergente și disruptive - efectul acestora asupra
securității globale

Dr. Adi MUSTAȚĂ

Drd. Cornelia JUDE

Decembrie 2022

Introducere

Era conectivității informaționale atrage după sine noi provocări și obstacole de depășit în ceea ce privește securitatea globală. Schimbările aduse de globalizarea extinsă și dezvoltarea rapidă a tehnologiilor informaționale ar fi trebui să însemne coordonare și cooperare internațională care să servească binelui comun. Cu toate acestea, monitorul global al conflictelor al Centrului pentru Acțiune Preventivă înființat de Consiliul pentru Relații Externe ale Statelor Unite relevă că peisajul securității mondiale la finele anului 2022 este în continuare unul marcat de instabilitate, violență și conflicte militare, în prezent existând nu mai puțin de 27 de conflicte aflate în desfășurare. Instabilitatea politică din Liban, Egipt și Venezuela, disputele teritoriale dintre Turcia și grupurile armate kurde, tensiunile dintre China și Taiwan, războaiele civile din Afganistan, Libia, Yemen, precum și recentul conflict teritorial ruso-ucrainean, declanșat la începutul anului 2022, sunt doar câteva exemple care evidențiază nevoia de a obține informații superioare în domeniul militar.

Când facem referire la procesul decizional uman și procesele cognitive superioare ce îl caracterizează (incluzând aici raționamentul, luarea deciziei și judecata socială) teoreticienii disting de regulă două tipuri de procese, denumite generic: *Sistemul 1* și *Sistemul 2*. Sistemul 1 este caracterizat de automatism, intuiție și asociativitate, deciziile fiind luate cu rapiditate, pe baza euristicii sau impulsului și necesitând un nivel de efort scăzut, în timp ce Sistemul 2 este caracterizat de cogniție superioară, reguli, rațiune, logică, secvențialitate și gândire analitică, deciziile fiind luate în timp, în mod conștient, și presupunând un nivel de efort ridicat. La nivel teoretic, superioritatea Sistemului 2 este clară, însă, în practică se dovedește că foarte multe dintre deciziile oamenilor sunt luate în mod intuitiv sau inconștient (Evans, 2008).

Procesele cognitive complexe care stau la baza fundamentării deciziilor militare se desfășoară adesea în condiții de stres operațional și de mediu, frecvente fiind situațiile cu miză ridicată și evenimentele traumatice. În aceste condiții, personalul militar trebuie să prezinte *reziliență cognitivă*. Aceasta presupune capacitatea ființelor umane de a depăși efectele negative ale stresului asupra funcționării cognitive normale (Bolton et al., 2008). Analizând un eșantion de infanteriști în serviciu activ al Armatei Statelor Unite ale Americii (SUA) și membrii ai Echipei Speciale de Reacție, ambele categorii având pregătire avansată în utilizarea armelor de foc cât și experiență și formare pentru îndeplinirea sarcinilor complexe în medii periculoase, Gamble et al., 2018 au demonstrat că în condiții de stres accentuat, fiind nevoiți să identifice inamicul sau aliatul

într-o situație de tipul „trage – nu trage”, militarii tind să facă mai multe erori cognitive, identificând în mod eronat aliații ca fiind inamici și viceversa.

Martin et al., 2019 demonstrează că o serie de *factori de stres de mediu*, incluzând temperaturile înalte, frigul sau altitudinea au consecințe negative asupra performanței personalului militar. S-a dovedit că în fața modificării extreme a condițiilor de mediu, militarii efectuează cu greutate sarcini dificile sau desfășurate în condițiile unei informării insuficiente, fiind predispuși la a face erori de judecată. Totodată, *variabilele fiziologiei umane*, incluzând lipsa exercițiului fizic sau suprasolicitarea fizică, oboseala datorată activităților militare susținute, privarea de somn sau malnutriția conduc la scăderea performanței sarcinilor cognitive (Martin et al., 2019).

Studii recente subliniază faptul că schimbările induse de factorii de stres asupra proceselor cognitive nu pot fi detectate în fază incipientă printr-o analiză imediată a performanței personalului militar, scăderea performanței acestora având loc treptat. Efectele factorilor de stres asupra militarilor se manifestă, în timp, prin scăderea eficienței operațiunilor (Flood & Keegan, 2022). Cu toate că *mecanismele de coping psihologice și fiziologice*, discutate pe larg în (Hancock, 1989), au capacitatea de a amortiza efectele stresului asupra performanței cognitive și de a diminua erorile de gândire, literatura recentă (Kai, 2016) subliniază că în combinație cu factorii contextuali, biasurile cognitive conduc la evaluări eronate și decizii militare slabe, atât la nivel strategic, cât și operațional.

Locotenent-colonelul Michael J. Janser (US Army) punctează principalele biasuri cognitive și limitări ale rațiunii umane: (1) *euristica de disponibilitate* sau tendința de a considera o situație ca fiind acceptabilă pe baza frecvenței de expunere la situații similare în trecut; (2) *euristica de reprezentativitate* sau atribuirea caracteristicilor experiențelor trecute unor experiențe viitoare, utilizând prototipurile psihologice; (3) *ancorarea* sau estimarea rezultatelor viitoare pe baza rezultatelor trecute (Janser, 2007).

Suplimentar, literatura recentă din domeniul științelor sociale, psihologiei cognitive și economiei comportamentale relevă că procesul decizional uman are loc în condiții de raționalitate imperfectă, rezultatele acestuia fiind supuse unor limitări importante, precum: excesul de încredere sau de optimism, aprecierea eronată a dimensiunii eșantionului, apetența pentru risc, corelațiile iluzorii, vulnerabilitatea în fața informațiilor false sau incomplete și dezinformarea. (Kai, 2016) subliniază totodată că factorii de decizie sunt mai predispuși să acționeze pe baza excesului de încredere, atunci când aceștia au o pregătire avansată.

Aspectele anterior menționate demonstrează că dincolo de războaiele purtate pe câmpul de luptă, omenirea și securitatea acesteia se confruntă astăzi cu un război cognitiv. În condițiile în care suma cunoștințelor umane crește exponențial, modul de accesare, gestionare și analiză a informațiilor devine din ce în ce mai variat, iar limitările și vulnerabilitatea raționalității umane sunt înțelese, Hartley & Jobson, 2020 argumentează că *atingerea superiorității cognitive* devine imperativul central pentru asigurarea securității națiunilor, iar dezvoltarea internetului obiectelor (n.tr. Internet of Things – IOT) și a soluțiilor specifice *inteligenței artificiale* (IA) sunt cele care promit să conducă la optimizarea și eficientizarea proceselor decizionale.

I. Inteligența artificială pentru noua revoluție în afacerile militare

Ultimele două decenii au însemnat progrese rapide pentru dezvoltarea soluțiilor bazate pe IA în medicină, economie, marketing, management și intelligence militar. Hynek și Solovyev (2022) sintetizează principalele caracteristici ale IA și analizează rolul acesteia în noua revoluție în afacerile militare, făcând trimitere la posibilele utilizări, potențialul IA în contextul dezvoltării militare, precum și politicile de securitate și regimul de reglementare al armelor. Obiectivul final al IA în domeniul militar este acela de a replica parțial sau total procesele specifice raționamentului uman, eliminând *bias*-ul, riscul, erorile de judecată și vulnerabilitatea factorilor decizionali în fața condițiilor fiziologice și psihologice extreme, garantând astfel avantajul competitiv, conducerea strategică, activismul politic și securitatea națiunii (Hynek, & Solovyeva, 2022).

În *Tabelul 1* sunt descrise principalele capacități și tehnologii specifice IA, descrise de (Mariani & Jenkins, 2019) în contextul pregătirii forțelor militare.

Tabel 1 Tehnologii și capacități IA pentru performanța forțelor militare

	Limbaajul cognitiv (n.tr. - cognitive language)	Recunoaștere vizuală computerizată (n.tr. - computer vision)	Automatizarea supravegheată (n.tr. - robotic process automation)	Analiza predictivă (n.tr. – predictive analytics)
Descriere	Un set de tehnici statistice care permit analiza, înțelegerea și generarea limbajului uman, incluzând textul și vorbirea, pentru a facilita interfațarea cu mașinările.	Extragerea automată, analiza și înțelegerea informațiilor pe baza unei singure imagini sau a unei succesiuni de imagini, astfel modelând, replicând sau augmentând vederea umană cu ajutorul capacităților hardware și software.	Software care poate efectua procese de rutină prin replicarea modului în care oamenii interacționează cu aplicațiile cu ajutorul unei interfețe de utilizator și urmând reguli simple pentru a lua decizii.	Combină modelele bazate pe clase, în special învățarea automată (n.tr. – machine learning), pentru a analiza datele cu scopul de a prezice rezultatele și de a înțelege variabilele care contribuie la rezultatele finale.
Tehnologii și capacități	<ul style="list-style-type: none"> ▪ Procesarea limbajului natural (NLP) ▪ Semantica computațională ▪ Recunoașterea vorbirii ▪ Sintetizarea vorbirii ▪ Analiza sentimentelor și analiza textuală 	<ul style="list-style-type: none"> ▪ Recunoașterea imaginilor ▪ Analiza video ▪ Recunoașterea scrierii de mână ▪ Recunoaștere vocală ▪ Recunoașterea optică a caracterelor 	<ul style="list-style-type: none"> ▪ Automatizarea și configurarea proceselor ▪ Testarea interfeței grafice cu utilizatorul (GUI) ▪ Sistemele suport avansate pentru decizii 	<ul style="list-style-type: none"> ▪ Modelele statistice predictive ▪ Modelele Naive Bayes și alte modele probabilistice ▪ Rețele neuronale
Cazuri de utilizare pentru operaționalizarea militară	<ul style="list-style-type: none"> ▪ Analiza automată a rapoartelor de misiune ▪ Asistență pentru mentenanța echipamentului miliar pe baza manualelor de utilizare ▪ Chatbots pentru asistență în mentenanță 	<ul style="list-style-type: none"> ▪ Aplicații ale realității augmentate pentru mentenanță, logistică sau pregătirea personalului militar ▪ Automatizarea trasabilității stocurilor și logistica 	<ul style="list-style-type: none"> ▪ Automatizarea sarcinilor de raportare ▪ Monitorizarea și trasabilitatea materialelor militare ▪ Simplificarea sarcinilor de achiziție și aprovizionare 	<ul style="list-style-type: none"> ▪ Mentenanță și aprovizionare predictivă ▪ Evaluarea performanței personalului și a echipei ▪ Diagnoza echipamentului

Sursa: Traducere autori după (Mariani & Jenkins, 2019) [<https://www2.deloitte.com/us/en/insights/industry/public-sector/ai-military-readiness.html>]

Dezvoltarea soluțiilor complete de IA reprezintă în continuare un țel greu de atins, termenul de „*intelență artificială*” fiind utilizat ca termen-umbrelă pentru a face referire la multitudinea tehnologiilor, algoritmilor și capabilităților inteligenței augmentate.

II. Evoluția lingvisticii computaționale și a procesării limbajului natural

Dezvoltarea tehnologiilor disruptive, incluzând IA, înțelegerea hipertextului și NLP-ul au transformat succesiv modul în care societatea se raportează la interacțiunea mașinărie-minte. În urmă cu mai bine de trei decenii, Psotka (1989) propune dezvoltarea a două proiecte ample care utilizează tehnologii dedicate interpretării limbajului natural pentru asistarea sarcinilor și pregătirii militare: (1) *Maintenance Aid Computer for HAWK–Intelligent Institutional Instructor (MACH-III)* dezvoltat pentru a reduce complexitatea mentenanței, cu ajutorul a trei niveluri de abstractizare simbolică (simularea, hipergrafurile și hipertextul), și pentru a oferi instruire în întreținerea principalului radar al sistemului de rachete aeriene ghidate HAWK; și (2) *Building Robust Dual Grammar Exercisers (BRIDGE)*, bazat pe un lexicon predefinit, structurat ierarhic și rafinat din punct de vedere al semanticii, dedicat studiului traducerii automate a resurselor de specialitate și instruirii militare în limbi străine.

În 1991, Weinstein evaluează potențialul procesării avansate a vorbirii în cadrul sistemelor militare computerizate, punctând principalele competențe cunoscute până la acel moment, dintre care amintim (1) *securitatea comunicării vocale în bandă îngustă și foarte îngustă*; (2) *dezvoltarea rețelelor de calculatoare capabile să transmită voce și date*; (3) *recunoașterea vorbirii în aeronavele militare, managementul luptei și unitățile pentru controlul traficului aerian*; și (4) *eliminarea zgomotului și a interferențelor pentru ascultătorii umani* (Weinstein, 1991).

Tot Weinstein este cel care prezintă principalele oportunități pentru dezvoltarea sistemelor integrate de procesare a vorbirii, incluzând terminalele integrate de comunicații voce-date, sistemele interactive pentru îmbunătățirea vorbirii, sistemele avansate pentru controlul traficului aerian, sistemele suport pentru comandă și control, inclusiv managementul luptei și sistemele de traducere în limba vorbită.

Manning & Schütze (1999) dezvoltă modelele statistice și algoritmica necesare instrumentelor NLP, argumentând că modelele probabilistice pot fi la fel de explicative ca cele ne-probabilistice, având însă avantajul că cele probabilistice pot explica și fenomenele caracterizate de incertitudine sau incompletitudine, așa cum este limbajul uman. Potrivit acestuia, un sistem

NLP eficient trebuie să întrunească următoarele caracteristici: (1) *capacitatea de a elimina ambiguitatea referitoare la sensul cuvintelor*; (2) *clasificarea cuvintelor*; (3) *analiza structurii și domeniului sintactic*, și în cele din urmă, (4) *asistarea deciziilor*.

Procesarea datelor de intrare, multilingvismul și recunoașterea vorbirii sunt abordate de (Langanke, 2007), făcând trimitere la două aplicații practice ale NLP-ului funcționale la acea vreme: (1) *intrarea vocală directă și controlul vocal direct* din cadrul sistemelor de pilotare ale aeronavelor militare Eurofighter/Typhoon, care utilizau primul sistem de intrare vocală pentru a oferi pilotului un mod de comandă și control asupra funcțiilor necritice ale aeronavelor; și (2) *și sistemele de comerț electronic de tip business-to-business*.

Langanke (2007) argumentează că cercetarea și dezvoltarea soluțiilor NLP dedicate interpretării în timp real a vorbirii și controlului vocal trebuie să se axeze pe simularea limbajului natural în condițiile existenței unui număr finit de medii de utilizare a acestuia, însă a unui număr infinit de cazuri de utilizare, astfel subliniind subiectivitatea și ambiguitatea caracteristice limbajului uman. În viziunea acestuia, competența lingvistică este un proces continuu de învățare, astfel că sistemele NLP trebuie să fie adaptabile, bazându-se pe reguli predefinite doar într-o oarecare măsură și necesitând să includă procese evolutive controlate sau necontrolate ale limbajului.

Dacă până la acea vreme, cercetarea s-a devotat exclusiv înțelegerii limbajului uman sub formă scrisă sau vorbită, anul 2007 are o contribuție importantă pentru includerea comunicării multimodale în NLP. Asociația pentru Lingvistică Computațională (ACL) a SUA își unește forțele în cadrul conferinței ACL 2007 din Praga, pentru a dezbate abordarea limbajului natural încorporat (n.tr. - embodied natural language). Principalele rezultate ale conferinței includ studiul reproducerii comportamentului uman în dezvoltarea agenților robotici, calculul distribuțiilor vocale în cadrul conversațiilor cu multiple persoane, asistenților virtuali pentru parcurgerea traseelor virtuale 3D, sistemelor de autentificare biometrică multimodale, precum și studiul agenților conversaționali încorporați, care pot reproduce atât limbajul verbal, cât și cel non-verbal. La începutul anilor 2010, studiul NLP-ului se dedică conceptelor precum învățarea caracteristicilor sau a reprezentării și dezvoltarea rețelelor neuronale profunde care permit analiza, procesarea și modelarea eficientă a limbajului natural (Glorot & Bengio, 2010; Goldberg, 2015).

Cu toate că cele mai importante concluzii cu privire la înțelegerea limbajului uman cu ajutorul statisticii, algoritmilor și mașinărilor au fost formulate în urmă cu aproape două decade,

preocuparea pentru dezvoltarea tehnologiilor emergente complexe dedicate pentru asistarea deciziilor și aplicării NLP-ului în domeniul militar este de mare actualitate în zilele noastre.

III. Evaluarea conceptuală și terminologie de specialitate

Procesarea limbajului natural (NLP) este o sub-ramură a IA, cuprinzând tehnologia și domeniul de studiu axate pe procesarea, trierea, înțelegerea și interpretarea limbajului natural, inclusiv a datelor nestructurate, în mod automat, cu ajutorul calculatoarelor. Obiectivul central pentru NLP este de a permite calculatoarelor să efectueze sarcini complexe asupra limbajului natural. Sarkar (2019) definește limbajul natural ca fiind orice limbaj uman dezvoltat în mod natural și care urmează un sistem semantic și sintactic specific.

În componența NLP se disting două elemente specifice: *înțelegerea limbajului natural* (NLU) și *generarea limbajului natural* (NLG). Delimitarea dintre cele trei concepte – NLP, NLU și NLG, precum și principalele funcționalități pot fi observate în *Figura 1*.

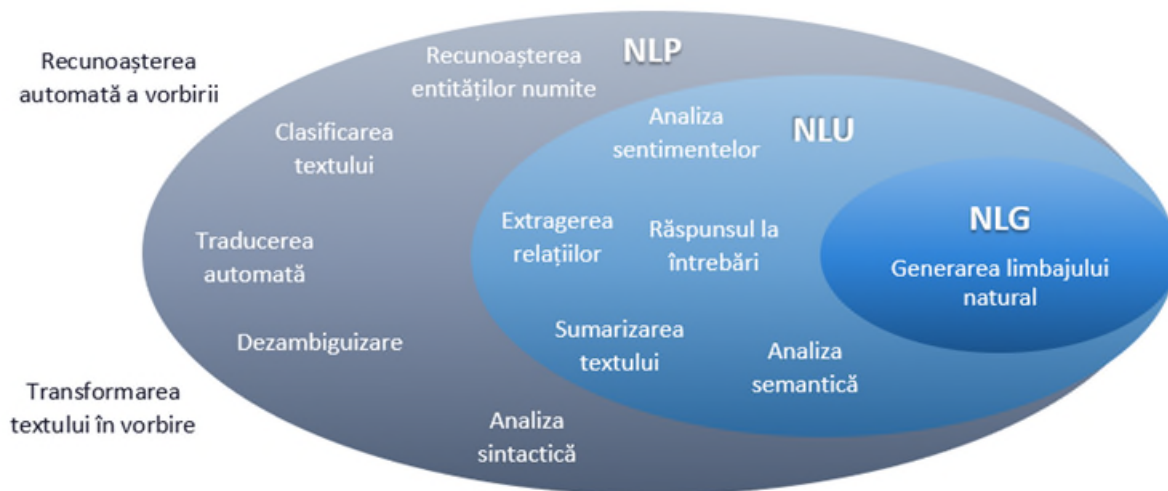


Figura 1 Delimitarea conceptelor de NLP, NLU și NLG. Principalele capabilități.

Sursa: Adaptare autori pe baza Egger, & Gokce, 2022

Înțelegerea limbajului natural (NLU) este o aplicație a IA, care utilizând analiza sintactică și semantică a textului sau a vorbirii, permite determinarea sensului limbajului natural. Generarea limbajului natural (NLG) face referire la IA conversațională și este definit ca acel „*subdomeniu al inteligenței artificiale și al lingvisticii computaționale care se preocupă de construcția de sisteme informatice care poate produce texte ușor de înțeles în engleză sau în alte limbi umane din unele non-subiacente – reprezentarea lingvistică a informației*” (Reiter, & Dale, 1997).

Recunoașterea entității numite (sau identificarea entității) este o procedură statistică avansată de extragere a informațiilor, care urmărește localizarea și clasificarea entităților numite în categorii predefinite (persoane, organizații, nume, ani, ș.a.m.d.). Cu ajutorul sistemelor de etichetare, acestor entități le pot fi atribuite token-uri specifice (Egger, & Gokce, 2022).

Etichetarea parțială a vorbirii presupune identificarea părții de vorbire a fiecărui cuvânt dat, pe baza definiției și a contextului în care este utilizat. Aceasta este utilizată pentru a face distincția dintre situațiile în care aceeași formă gramaticală a cuvântului poate fi utilizată ca părți de vorbire diferite și devine util pentru determinarea cuvintelor lipsă din cadrul modelelor lexicale sau gramaticale predefinite (Sketch Engine, 2022).

Clasificarea textului este o tehnică de învățare automată care atribuie un set de categorii predefinite unui text. De regulă, clasificarea textului este utilizat pentru organizarea documentelor similare în biblioteci comune, în funcție de anumite specificații. (Wang et al., 2013) O utilizare a acestei capabilități face referire la sortarea email-urilor primite și identificarea spam-ului.

Un alt tip de aplicație pentru clasificarea textului face referire la **analiza sentimentelor**. Analiza sentimentelor presupune „studiul computațional al oamenilor, opiniilor, aprecierilor, atitudinilor și emoțiilor exprimate față de entități, indivizi, probleme, evenimente, subiecte și atributele lor” (Liu, & Zhang, 2012). Spre exemplu Bakshi et al., 2016 utilizează o metodologie etapizată pentru a determina influența sentimentelor din comentariile utilizatorilor platformei Tweeter asupra fluctuației prețurilor acțiunilor.

Dezambiguizarea (sau rezoluția de bază a deferenței) permite identificarea tuturor expresiilor lingvistice care fac referire la aceeași entitate din lumea reală. Aceasta devine esențială pentru înțelegerea automată a textului și facilitarea sarcinilor de extragere a informațiilor la nivel înalt, cum ar fi sumarizarea textului sau răspunsul la întrebări (Brack et al., 2021).

O parte importantă dintre capabilitățile NLP sunt deja incorporate în cadrul sistemelor analitice ale zilelor noastre. Spre exemplu, portalul de business intelligence Metric Insights' Push Intelligence, examinează sursele de date disponibile, urmând ca pe baza regulilor predefinite și a analizei statistice să alerteze utilizatorii cu privire la modificările semnificative și anomaliiile setului de date (Watson, 2017). Căutare inteligentă și textul predictiv permite motoarelor de căutare să personalizeze experiențele de navigare pe internet, iar traducerea automată, prezentă în aplicații precum Google Translate sau DeepL permite calculatoarelor să realizeze traducerea limbajului introdus dintr-o limbă de referință în oricare alta (Sarkar, 2019)

Qin et al., 2021 demonstrează că modelele avansate de procesare a limbajului natural pot contribui la screening-ul rapid al titlurilor și rezumatelor literaturii de specialitate, contribuind la realizarea recenziilor sistematice a literaturii de specialitate. Proiectarea acestuia are la bază un set de date extins, format din studii controlate randomizate privind inhibitorii co-transportatorului 2 de sodiu-glucoză pentru tratamentul diabetului zaharat de tip 2, reprezentând setul de date de antrenament pentru dezvoltarea modelului și învățarea clasificării pe baza fragmentelor de text extrase. Modelul propus a obținut o sensibilitate de 96% și o specificitate de 78%. Din totalul de 947 de lucrări incluse, 340 de lucrări au fost considerate relevante, reducând astfel volumul de muncă cu 64,1%. Suplimentar, clasificarea automată a eliminat doar 8 din 180 de publicații eligibile, dintre care, pe baza parcurgerii textului integral, nici una nu a fost inclusă în realizarea recenziei sistematice finale.

Una dintre cele mai cunoscute aplicații ale NLP pentru asistarea deciziilor este asistentul inteligent **IBM Watson**, dezvoltat în anul 2007 pentru a concura împotriva participanților umani în cadrul competiției de întrebări deschise „Jeopardy!”. În anul 2011, IBM Watson câștigă competiția împotriva celor mai bine clasați doi jucători, Ken Jennings și Brad Rutter. Sistemul care stă la baza asistentului inteligent IBM poartă numele de DeepQA și respectă arhitectura sistemelor probabilistice bazate pe dovezi, iar pentru câștigarea jocului de „Jeopardy!” acesta a incorporat peste 100 de tehnici diferite pentru procesarea limbajului natural, identificarea surselor, găsirea și notarea dovezilor, fuzionarea și ierarhizarea ipotezelor (Ferrucci et al., 2010).

Principiile care au condus la elaborarea metodologiei de dezvoltare a DeepQA sunt paralelismul masiv (n.tr. – massive parallelism), multitudinea sistemelor expert, estimarea generală a încrederii și integrarea de cunoștințe vaste (Ferrucci et al., 2010).

- Conceptul de paralelism reprezintă tehnica de programare și capacitatea calculatoarelor de a efectua sarcini coordonate în paralel, în timp ce *paralelismul masiv* face referire la utilizarea unui număr mare de elemente procesoare, care realizează simultan aceeași sarcină, luând în considerare multiple date, interpretări și ipoteze disponibile (Nechita, Crișan, & Talmaciu, 2008).
- Integrarea *sistemelor expert multiple* facilitează integrarea și evaluarea contextuală a unui set extins de întrebări probabilistice și permite analiza conținutului.
- *Estimarea generală a încrederii* permite atribuirea unui scor de încredere fiecărui răspuns generat, evaluând interpretările posibile. Un element integrat permite

evaluarea și ierarhizarea scorurilor de confidență obținute pentru alegerea răspunsului corect.

- *Integrarea de cunoștințe vaste* permite înțelegerea semanticii stricte, precum și a caracteristicilor sintactice superficiale, „valorificând multe ontologii slab formate” (Ferrucci et al., 2010).

În *Figura 2* este reprezentată arhitectura la nivel înalt a sistemului DeepQA.

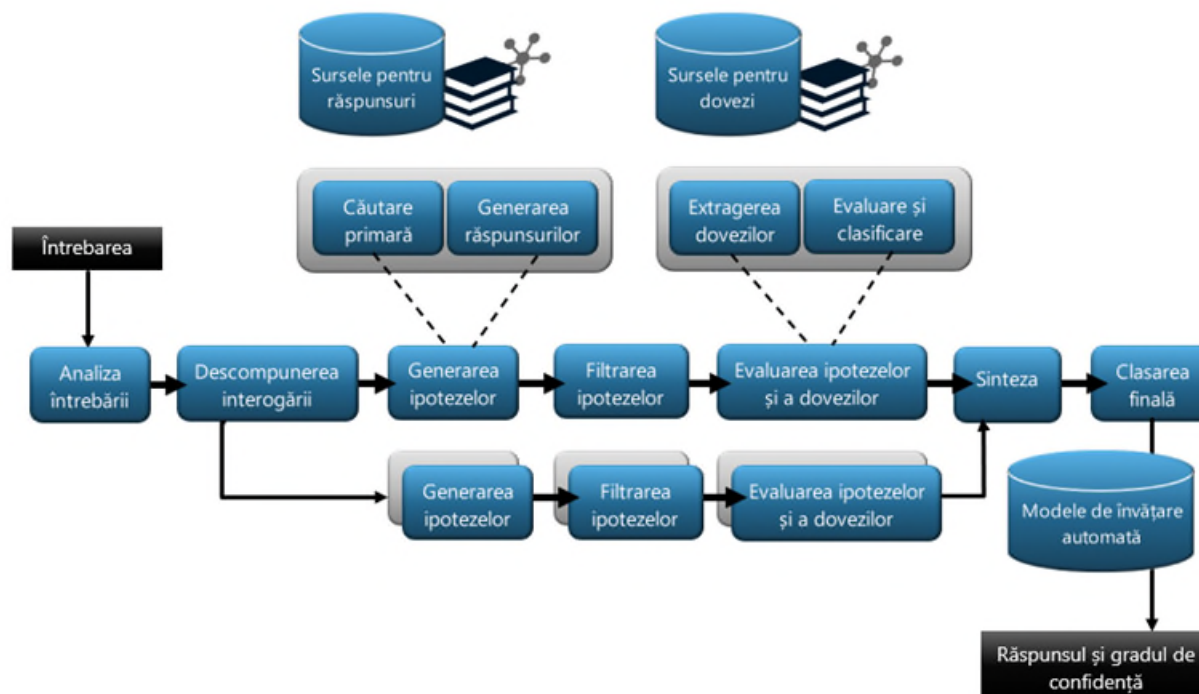


Figura 2 Arhitectura la nivel înalt a sistemului DeepQA

Sursa: Adaptare autori pe baza Ferrucci et al., 2010

Prima etapă în dezvoltarea aplicației DeepQA are la bază *achiziționarea de conținut* incluzând identificarea și colectarea surselor de date relevante pentru fundamentarea răspunsurilor și a dovezilor. Achiziția de conținut presupune atât o evaluare manuală a întrebărilor din spațiul problemei, cât și o analiza a domeniului fundamental conex problemei, pentru care pot fi utilizate evaluările automate sau statistice. În cadrul primului sistem IBM Watson, sursele de date au inclus un număr extins de enciclopedii, articole de știri, opere literare, dicționare și alte lucrări similare. Procesul de achiziționare de conținut, poate fi împărțit în patru etape: (1) *identificarea surselor relevante și extragerea surselor secundare, conexe acestora*; (2) *extragerea fragmentelor de text din cadrul surselor secundare selectate*; (3) *stabilirea relevanței fragmentelor de text extrase, în*

funcție de sursele relevante și (4) crearea bazei de cunoștințe pe baza celor mai relevante fragmente textuale. În completarea resurselor textuale, DeepQA analizează și extrage conținut și din cadrul ontologiilor, taxonomiilor sau altor tipuri de conținut de date structurare și nestructurate.

Analiza întrebării presupune clasificare întrebărilor posibile după tipul acestora, identificarea semnificațiilor ascunse, a constrângerilor, a definițiilor și a relațiilor semantice sau dintre părțile de vorbire. În cazul întrebărilor compuse, *descompunerea interogării* este utilizată pentru a împărți problema analizată în sub-probleme, considerându-se că răspunsul final va avea un grad de încredere mai mare o dată ce au fost luate în considerare toate dovezile colectate și toți algoritmi relevanți pentru rezolvarea fiecărei sub-probleme.

Generarea ipotezelor se bazează pe rezultatele obținute ca urmare a analizei întrebării și are loc în două etape: (1) *căutarea primară* și (2) *generarea răspunsurilor*. Scopul *căutării primare* este de a identifica cât mai multe surse relevante în legătură cu întrebarea inițială. *Generarea răspunsurilor* presupune formularea unui set de răspunsuri posibile pe baza specificațiilor întrebării și extragerii fragmentelor de text din sursele identificate. Pentru *filtrarea ipotezelor de răspuns*, sunt utilizați algoritmi specifici care atribuie un scor fiecărei variante de răspuns. Răspunsurile care sunt considerate a fi cele mai relevante parcurg pasul următor de *evaluare a ipotezelor și dovezilor*, în cadrul căruia fiecare răspuns este comparat cu sursele de date relevante pentru identificare similitudinii textuale. Pentru simplificarea utilizării, IBM Watson realizează o agregare a scorurilor în cadrul unui *profil general al dovezilor*, care grupează caracteristicile individuale în dimensiuni agregate bazat pe dovezi, pentru a oferi o imagine de ansamblu a grupul de caracteristici (“G.6 Passage Retrieval and Question Answering,” 2013).

Cu ajutorul algoritmilor de potrivire, normalizare și rezoluție de deferență, Watson identifică răspunsurile echivalente sau înrudite și permite *sinteza* acestora pe baza unei anumite caracteristici comune pentru a computa scorurile finale. *Clasarea finală* presupune ierarhizarea răspunsurilor posibile pe baza scorului final și estimarea gradului de confidență a fiecăruia. Aceasta implică o abordare bazată pe *învățare automată* care necesită expunerea sistemului la un set de întrebări de instruire cu răspunsuri cunoscute și antrenarea sistemului pentru a alege răspunsul corect pe baza scorurilor (Ferrucci et al., 2010).

Conducătorul proiectului de cercetare care a contribuit la dezvoltarea IBM Watson, David Ferruci punctează în anul 2013 că aceeași arhitectură DeepQA care a condus la câștigarea jocului de „Jeopardy!” oferă premisa dezvoltării sistemelor de sprijin a deciziilor clinice, având

capacitatea de aborda provocările cognitive cu care se confruntă practicienii și oferind asistență valoroasă pentru diagnosticul diferențial (Ferrucci et al., 2013).

În anul 2013, Colegiul de Medicină Baylor împreună cu IBM Research Center realizează un studiu pentru dezvoltarea capabilităților Watson în ceea ce privește identificare kinazelor care ar putea realiza fosforilarea proteinei P53. Proiectarea studiului a presupus definirea surselor prin includerea literaturii de specialitate publicată până în anul 2002 cu privire la fosforilarea proteinei P53 și extragerea fragmentelor de text relevante pentru determinarea legăturilor. Ulterior, kinazele identificate au fost comparate cu literatura disponibilă la Biblioteca Națională de Medicină a Statelor Unite – MEDLINE pentru identificarea kinazelor finale. Rezultatele studiului au condus la identificarea a 9 kinaze având potențialul de a fosforila proteina P53, dintre care 7 au fost descoperite și validate prin experimente medicale publicate în perioada 2003-2013 (Spangler et. al., 2014).

Suwanvecho et al., 2019 împreună cu o echipă de medici oncologi din cadrul Spitalului Internațional Bumrungrad din Bangkok, Thailanda, realizează o evaluare anonimă a opțiunilor de tratament identificate direct de asistentul inteligent IBM Watson for Oncology (WFO), sau de către un board multidisciplinar din cadrul spitalului. Din eșantionul de 228 de tratamente administrate pacienților, 174 au fost identice cu opțiunea WFO. Cu privire la cele 54 de perechi neidentice s-a determinat că 88,6% dintre deciziile de tratament au fost fie identice, însă formulate diferit, fie considerate la fel de acceptabile de către oncologi. Motivele identificate pentru discordanță dintre practica clinică și opțiunile WFO au fost în măsură de 70% datorate preferinței oncologului, în timp ce 20% dintre discordanțe au fost atribuite preferinței pacientului și 10% disponibilității tratamentului WFO.

IV. Procesarea limbajului natural și aplicațiile sale în domeniul militar

Schirmer et. al., 2021 publică la mijlocul anului 2021 o colecție de rezultate observate și lecții învățate ca urmare a proiectelor grupului nonprofit american RAND Corporation, bazate pe instrumentele și metodele specifice NLP. Potrivit acestora, principalele aplicații includ capabilități de clasificare a documentelor, precum: (1) *clasificarea datelor contractuale pentru a înțelege mixtul forței de muncă armate;* (2) *precizarea promovărilor ofițerilor militari pe baza sarcinilor scrise;* (3) *estimarea forței de acțiune a unităților și organizațiilor militare pe baza instrucțiunilor de comandă ale comandanților;* (4) *identificarea posibililor șicanatori (n.tr. – troll) ruși pe baza*

mesajelor postate pe Twitter; (5) descoperirea teoriilor conspirației promovate prin intermediul rețelelor sociale; (6) clasificarea locurilor de muncă, pe baza descrierilor postate în anunțurile de angajare; (7) prezicerea activității utilizatorilor Twitter pe baza postărilor trecute; (8) stabilirea modului de diagnostic al psihologilor pe baza însemnărilor clinice; și (9) identificarea studiilor, finanțate de agenții federale, care desfășoară cercetări pentru servicii de sănătate și asistență primară.

Alte utilizări NLP amintite de studiului grupului RAND Corporation, cu referire la domeniul militar, sunt: *(1) compararea limbajului utilizat pentru evaluarea în scris din rapoartele ofițerilor selectați și omiși pentru comanda batalionului; (2) căutarea și extragerea informațiilor din jurnalele de mentenanță ale aeronavelor; (3) sumarizarea textului și identificare subiectelor specifice politicii bioteroriste; (4) indexarea răspunsurilor furnizorilor de soluții cloud la solicitările de informații transmise de o agenție federală; (5) extragerea informațiilor cu privire la urmărirea cibernetică din procesele judiciare și (6) utilizarea știrilor pentru a răspunde întrebărilor referitoare la actele majore de violență, inclusiv împușcăturile în masă.* Principalele concluzii ale desfășurării proiectelor anterior amintite relevă câteva dintre limitele și provocările cercetării aplicațiilor NLP în domeniul militar.

Pe de-o parte, s-a dovedit că sarcinile NLP se desfășoară de regulă succesiv, astfel ***rezultatele unui proces NLP putând reprezenta date de intrare pentru următorul proces.*** Acest aspect se dovedește a fi extrem de anevoios în cadrul proiectelor ample, care necesită efectuarea unui număr mare de sarcini succesive și în special, pentru personalul nefamiliarizat cu instrumentele NLP sau istoricul proiectului. Totodată, ***algoritmii de învățare automată sunt susceptibili învățării inechitabilității***, atunci când datele de antrenament prezintă *bias*-uri semnificative. Mai mult, s-a dovedit că ***rezultatele analizei textuale sunt mai degrabă relevante la nivel de mesaj sau individ***, astfel restrângând aplicabilitatea NLP doar la nivel tactic, omițând nivelele operațional sau strategic.

Pe de-altă parte, cu toate că datele utilizate pentru construirea modelelor au fost colectate, securizate și procesate în mod corespunzător, ***confidențialitatea și securitatea*** datelor rezultate de pe urma proceselor NLP specifice rămâne un considerent vulnerabil (Klymenko, Meisenbacher, Matthes, 2022). Schirmer et. al., 2021 punctează că rezultatele procesării NLP a datelor de intrare, inclusiv modelele lingvistice generate, pot conține în continuare date de identificare personală (PII) sau terminologie care ar necesita securizarea.

În pofida limitărilor anterior expuse, preocuparea armatei **Statelor Unite ale Americii** (SUA) pentru dezvoltarea soluțiilor bazate pe NLP este în continuă creștere. La data de 16 Noiembrie 2022, prin intermediul Centrului de Sprijin a Achizițiilor armatei și a Programului de Cercetare în Inovarea Întreprinderilor Mici (SBIR), armata SUA lansează o cerere de propuneri pentru proiecte dedicate cercetării și dezvoltării aplicațiilor militare bazate pe procesarea limbajului natural. Întreprinderile calificate urmează să primească suportul științific, asistență pentru protecția proprietății intelectuale, sprijin pentru comercializarea și tranziția tehnologică, asistență în reglementare și o finanțare de până la 50.000 de dolari.

Obiectivul inițiativei armatei SUA este de a dezvolta modele de IA și învățare automată (n.tr. – machine learning – ML) pentru a crește capacitățile NLP în vederea detectării automate a relațiilor între observațiile extrase din date și a agregării acestora (US Army Acquisition Support Center, 2022). Potrivit cererii de proiecte, unele observațiile necesare agregării includ: culoarea părului, naționalitatea, modelul tancului, armura tancului. Proiectele ar urma să propună modele NLP pentru recunoașterea, analiza și exploatarea modelelor, incluzând recunoașterea automată și analiza tiparelor, inclusiv a indicațiilor, avertismentelor sau a cursurilor de acțiune.

Agenția pentru Proiecte de Cercetare Avansată a Apărării a SUA (DARPA) desfășoară deja programul *Deep Exploration and Filtering of Text* (DEFT) prin intermediul căruia urmărește extragerea automată a informațiilor relevante din punct de vedere operațional din seturi de date nestructurate, pentru a susține eforturile analiștilor apărării și analiza automată (Onyshkevych, n.d.). Programul DARPA, *The Semantic Forensics* lansat în anul 2019 urmărește dezvoltarea soluțiilor bazate pe IA și NLP pentru identificarea informațiilor multi-media falsificate și eliminarea *deep fake*-urilor. *The Semantic Forensics* utilizează algoritmi de detectare semantică, pentru a determina dacă datele multi-media au fost manipulate și algoritmi de atribuire pentru a identifica dacă acestea provin de la o anumită organizație sau individ. Suplimentar, algoritmi de caracterizare sunt utilizați pentru a demonstra dacă falsurile au fost generate sau manipulate în scopuri rău intenționate. Obiectivul central al acestui proiect urmărește detectarea, atribuirea și caracterizarea campaniilor de dezinformare adverse.

Un alt program DARPA lansat în anul 2021 urmărește studiul înțelegerii culturale computaționale (CCU) cu ajutorul instrumentelor specifice procesării profunde a limbajului natural (n.tr. – deep NLP), având ca principale direcții de cercetare: identificarea automată a normelor socioculturale, generalizarea recunoașterii emoțiilor în diferite culturi, determinarea

schimbărilor de impact în practicile de comunicare uzuale, la intervale de timp diferit și asistența pentru dialogul care implică interacțiunea interculturală.

Federația Rusă recunoaște importanța strategică a adoptării elementelor de IA în 2015, prin debutul programului intitulat *Robotization of Weapons and Military Equipment*. Cu toate că programul nu s-a concretizat în dezvoltarea propriu-zisă a tehnicii militare robotice, acesta a contribuit semnificativ la cercetarea și dezvoltarea modelelor experimentale pentru desfășurarea operațiunilor la sol (Kozyulin, 2019). În 2016, guvernul rus a adoptat *Strategia de Dezvoltare Științifică și Tehnologică a Federației Ruse*, având ca principal obiectiv, printre altele, tranziția către sistemele digitale avansate, incluzând sistemele robotice, Big Data, învățarea automată și IA.

În 2017, cea mai mare bancă de stat rusă, Sberbank semnează un acord de cooperare strategică cu Institutul de Fizică și Tehnologie din Moscova (MPTI) având ca direcții prioritare asigurarea cooperării pentru dezvoltarea proiectelor științifice de cercetare în analiza datelor, învățarea automată și IA. (Sberbank, 2017). Totodată, Sberbank și MPTI cofinanțează proiectul *iPavlov Neurointelligence*, având ca scop dezvoltarea algoritmilor de învățare automate și crearea sistemelor IA conversaționale cu ajutorul tehnologiilor specifice procesării limbajului natural, recunoașterii vorbirii și viziunii computerizate.

Un an mai târziu, ca rezultat al conferinței „*Inteligența artificială: probleme și modalități de a le rezolva - 2018*”, Ministerul Apărării al Federației Ruse adoptă un plan pentru accelerarea dezvoltării soluțiilor IA, acoperind zece direcții prioritare, dintre care amintim: (1) *înființarea unui consorțiu compus din membrii Academiei Ruse de Științe, Ministerul Educației, Ministerul Industriei și Ministerul Apărării pentru analiza Big Data și dezvoltarea IA*; (2) *intensificarea eforturilor de creare a fondului de algoritmi analitici și programe pentru dezvoltarea sistemelor automatizate*; (3) *formarea și recalificarea specialiștilor în domeniul IA*; (4) *crearea unui laborator pentru testarea soluțiilor software și hardware IA*; (5) *monitorizarea dezvoltării globale IA*; (7) *desfășurarea jocurilor militare pe o gamă largă de scenarii pentru a determina impactul IA la nivel tactic, operațional și strategic* și (8) *verificarea conformității tehnologiilor IA pentru îndeplinirea cerințelor date* (Ministerul Apărării al Federației Ruse, 2018).

Potrivit Konaev & Dunham, 2020 și Wijermars & Lehtisaari, 2021, Roskomnadzor — autoritatea executivă federală rusă responsabilă cu supravegherea conținutului online și media, monitorizează site-urile web, precum și serviciile digitale de mesagerie, pentru identificarea informațiilor catalogate ca fiind interzise și includerea acestora într-un registru special, denumit

„Blacklist” pentru a comanda furnizorilor de servicii de internet blocarea accesului utilizatorilor la acestea. Konaev & Dunham, 2020 punctează că Roskomnadzor ar fi recrutat experți din cadrul Școlii Superioare de Economie a Universității Naționale de Cercetare din Moscova pentru a-și îmbunătăți sistemul automat de monitorizare a internetului. Din punct de vedere tehnic, acesta este alcătuit din trei tehnologii: (1) „*Simona*” - *sistemul de monitorizare al abaterilor, care navighează pe site-urile web, inclusiv în comentariile cititorilor, din registrul Roskomnadzor și semnalează operatorilor acele materiale care conțin cuvinte cheie predefinite pentru a detecta conținutul considerat ilegal*; (2) „*Sirena*” – *sistemul care permite înregistrarea încălcărilor și transferul acestora către inspectorii Roskomnadzor responsabili*; și (3) „*Revizor*” – *sistem pentru monitorizarea site-urilor web care trebuie să fie blocate de furnizorii de internet*.

În contextul conflictului ruso-ucrainean actual, Keip, Haren, & Roncalli (2022), demonstrează abilitățile NLP aplicat pentru procesarea a peste 50.000 de texte pe zi extrase din știri și publicații guvernamentale, în 27 de limbi diferite, axându-se pe extragerea în timp real a legăturilor cauzale. Autorii numesc această abordare „înțelepciunea mulțimilor” și punctează că aceasta permite actualizarea automată a informațiilor precum și formularea previziunilor indicatorilor economici, inclusiv prețurile, producția, profitul, produsul intern brut (PIB-ul), ratele inflației și cursurile de schimb, dar și legăturile de cauzalitate dintre acestea.

Suplimentar, Tkachenko, & Guo, 2019 analizează interacțiunile utilizatorilor platformei de socializare Reddit, punând accentul pe perioada alegerilor din Ucraina din 2019. Acesta demonstrează cum în contextul conflictelor digitale dintre grupuri distincte, utilizând analiza sentimentelor utilizatorilor individuali, inclusiv varianța și entropia, pot fi determinate interacțiunile dintre grupuri și pot fi formulate ipotezele cu privire la rolul și evoluția fiecărui utilizator în cadrul grupurilor. Rezultatele cercetării urmează să contribuie la utilizarea NLP pentru identificarea timpurie a comportamentului radical în cadrul platformelor digitale.

V. Diseminarea rezultatelor cercetării

– Răpan I., Zaman, G., Suciuc, M.-C., Purcărea, V.-L., **Jude, Cornelia Rodica**, Radu A.-V., Catană, A., Radu, A.-C., 2022, *A Better Integration of Industrial Robots in Romanian Enterprises and the Labour Market*, Journal of Applied Sciences, 27 (pp. 1-27), ISSN: 2076-3417, <https://www.mdpi.com/2076-3417/12/12/6014> , MULTIDISCIPLINARY in SCIE edition (Q3), ENGINEERING, MULTIDISCIPLINARY in SCIE edition (Q2), MATERIALS SCIENCE,

MULTIDISCIPLINARY in SCIE edition (Q3), Impact Factor: 2.679 (2020); Factor de impact ultimii 5 ani: 2.736 (2020) ; AIS=0,409).

– **Marinel-Adi Mustață**, Ivona Răpan, Lucian Dumitrescu, Hristina Dobreva, Petko Dimov, Andrzej Lis, Eva Révayová, Vasile Mărineanu, Ruxandra Buluc, Cosmin Olariu, Alexandru Lucinescu, Cosmin Buță, *Disinformation via Fake News in Central and Eastern Europe. A Study on Cognitive Style and Epistemic Sophistication as Predictors of News Credibility Evaluation in Security and Defence Issues (ID IJPOR-2022-187)*, **articol aflat in evaluare** la jurnalul International Journal of Public Opinion Research, Impact Factor: 1.872.

Bibliografie

- [1] Bakshi, R.K., Kaur, N., Kaur, R., & Kaur, G. (2016). Opinion mining and sentiment analysis. *2016 3rd International Conference on Computing for Sustainable Global Development (INDIACom)*, 452-455.
- [2] Bolton, A., Yaroush, R., Staal, M., & Bourne Jr., L. (2008). Cognitive Performance and Resilience to Stress. *Biobehavioral Resilience to Stress*, 259–299. <https://doi.org/10.1201/9781420071788.ch10>
- [3] Brack, A., Müller, D. U., Hoppe, A., & Ewerth, R. (2021). Coreference Resolution in Research Papers from Multiple Domains. *Lecture Notes in Computer Science*, 79–97. https://doi.org/10.1007/978-3-030-72113-8_6
- [4] Cassell, J., & Heylen, D. (2007). *Proceedings of the Workshop on Embodied Language Processing - EmbodiedNLP '07*. Association for Computational Linguistics. N. Eight Street, Stroudsburg, PA, 18360. United States. <https://doi.org/10.3115/1610065>
- [5] Charemza, W., Makarova, S., & Rybiński, K. (2022). Economic uncertainty and natural language processing; The case of Russia. *Economic Analysis and Policy*, 73, 546–562. <https://doi.org/10.1016/j.eap.2021.11.011>
- [6] Chen, Y., Elenee Argentinis, J., & Weber, G. (2016). IBM Watson: How Cognitive Computing Can Be Applied to Big Data Challenges in Life Sciences Research. *Clinical Therapeutics*, 38(4), 688–701. <https://doi.org/10.1016/j.clinthera.2015.12.001>
- [7] Corvey, W. (2019). Semantic Forensics (SemaFor). Defense Advanced Research Projects Agency, US Department of Defense. <https://www.darpa.mil/program/semantic-forensics>
- [8] Corvey, W. (2021). Computational Cultural Understanding (CCU). Defense Advanced Research Projects Agency, US Department of Defense. <https://www.darpa.mil/program/computational-cultural-understanding>
- [9] Egger, R., & Gokce, E. (2022). Natural Language Processing (NLP): An Introduction. In: Egger, R. (eds) *Applied Data Science in Tourism. Tourism on the Verge*. Springer, Cham. https://doi.org/10.1007/978-3-030-88389-8_15

- [10] Evans J. S. (2008). Dual-processing accounts of reasoning, judgment, and social cognition. *Annual review of psychology*, 59, 255–278. <https://doi.org/10.1146/annurev.psych.59.103006.093629>
- [11] Ferrucci, D., Brown, E., Chu-Carroll, J., Fan, J., Gondek, D., Kalyanpur, A. A., Lally, A., Murdock, J. W., Nyberg, E., Prager, J., Schlaefer, N., & Welty, C. (2010). Building Watson: An Overview of the DeepQA Project. *AI Magazine*, 31(3), 59-79. <https://doi.org/10.1609/aimag.v31i3.2303>
- [12] Ferrucci, D., Levas, A., Bagchi, S., Gondek, D., & Mueller, E. T. (2013). Watson: Beyond Jeopardy! *Artificial Intelligence*, 199–200, 93–105. <https://doi.org/10.1016/j.artint.2012.06.009>
- [13] Flood, A., & Keegan, R. J. (2022). Cognitive Resilience to Psychological Stress in Military Personnel. *Frontiers in Psychology*, 13. <https://doi.org/10.3389/fpsyg.2022.809003>
- [14] G.6 Passage Retrieval and Question Answering. (2013). *Handbook of Information Science*, 423–429. <https://doi.org/10.1515/9783110235005.423>
- [15] Gamble, K. R., Vettel, J. M., Patton, D. J., Eddy, M. D., Caroline Davis, F., Garcia, J. O., Spangler, D. P., Thayer, J. F., & Brooks, J. R. (2018). Different profiles of decision making and physiology under varying levels of stress in trained military personnel. *International Journal of Psychophysiology*, 131, 73–80. <https://doi.org/10.1016/j.ijpsycho.2018.03.017>
- [16] Glorot, X. & Bengio, Y. (2010). Understanding the difficulty of training deep feedforward neural networks. *International Conference on Artificial Intelligence and Statistics*, 249–256.
- [17] Goldberg, Y. (2015). *A Primer on Neural Network Models for Natural Language Processing*. ArXiv: Computation and Language.
- [18] Hancock, P. A. (1989). A Dynamic Model of Stress and Sustained Attention. *Human Factors: The Journal of the Human Factors and Ergonomics Society*, 31(5), 519–537. <https://doi.org/10.1177/001872088903100503>
- [19] Harari, Y. N. (2018). *Homo Deus: A Brief History of Tomorrow (Illustrated)*. Harper Perennial.
- [20] Hartley, D. S., III, & Jobson, K. O. (2020). *Cognitive Superiority: Information to Power*. Springer Publishing.
- [21] Hynek, N., & Solovyeva, A. (2022). *Militarizing Artificial Intelligence: Theory, Technology, and Regulation (Routledge Studies in Conflict, Security and Technology)* (1st ed.). Routledge.
- [22] IBM Cloud Education. (2021, August 17). *Natural Language Processing (NLP)*. <https://www.ibm.com/cloud/learn/natural-language-processing>
- [23] Kai, C. (2016). *[PDF] Cognitive Biases: The Root of Irrationality in Military Decision-Making by CPT | Semantic Scholar*. <https://www.semanticscholar.org/paper/Cognitive->

Biases-:-The-Root-of-Irrationality-in-by-Kai/9d65465ca0728b7ae3daad92f4aa95ecb6302f03

- [24] Keip, M., Haren, P. & Roncalli, T. (2022) *When artificial intelligence meets economy: an analysis of the Ukraine war*. Investment Insights Blue Paper. <https://research-center.amundi.com/article/when-artificial-intelligence-meets-economy-analysis-ukraine-war>
- [25] Klymenko, O., Meisenbacher, S., & Matthes, F. (2022). Differential Privacy in Natural Language Processing. The Story So Far. ArXiv, abs/2208.08140.
- [26] Konaev, M., & Dunham, J. (2020). Russian AI Research 2010 to 2018. Topics, Trends, and Institutions. CSET Issue Brief. <https://cset.georgetown.edu/wp-content/uploads/CSET-Russian-AI-Research-2010-to-2018.pdf>
- [27] Kozyulin, V. (2019). Militarization of AI. Discussion Paper. A Russian Perspective. PIR Center (Russian Center for Policy Research). <https://stanleycenter.org/wp-content/uploads/2020/05/MilitarizationofAI-Russia.pdf>
- [28] Langanke, U. H. (2007). *Direct Voice Control Speech Data Entry and Database Query Models*. 2007 International Symposium on Logistics and Industrial Informatics. doi:10.1109/lindi.2007.4343522
- [29] Liu, B., & Zhang, L. (2012). A Survey of Opinion Mining and Sentiment Analysis. *Mining Text Data*.
- [30] LTC Michael J. Janser. (2007). Cognitive Biases in Military Decision Making: Civilian research project. In *Center for Strategic & International Studies* (No. ADA493560). U.S. Army War College. <https://apps.dtic.mil/sti/citations/ADA493560>
- [31] Manning, C. D., & Schütze, H. (1999). Foundations of Statistical Natural Language Processing (1st ed.). The MIT Press.
- [32] Mariani, J., & Jenkins, I. (2019, April 24). *Military readiness through AI*. Deloitte Insights. <https://www2.deloitte.com/us/en/insights/industry/public-sector/ai-military-readiness.html>
- [33] Martin, K., McLeod, E., Périard, J., Rattray, B., Keegan, R., & Pyne, D. B. (2019). The Impact of Environmental Stress on Cognitive Performance: A Systematic Review. *Human Factors: The Journal of the Human Factors and Ergonomics Society*, 61(8), 1205–1246. <https://doi.org/10.1177/0018720819839817>
- [34] Martin, K., Périard, J., Rattray, B., & Pyne, D. B. (2019). Physiological Factors Which Influence Cognitive Performance in Military Personnel. *Human Factors: The Journal of the Human Factors and Ergonomics Society*, 62(1), 93–123. <https://doi.org/10.1177/0018720819841757>

- [35] Ministerul Apărării al Federației Ruse. (2018). *Conferința „Inteligența artificială: probleme și modalități de a le rezolva - 2018”*. mil.ru. <https://mil.ru/conferences/is-intellekt.htm>
- [36] Munezero, M., Montero, C. S., Sutinen, E., & Pajunen, J. (2014). Are they different? Affect, feeling, emotion, sentiment, and opinion detection in text. *IEEE Transactions on Affective Computing*, 5(2), 101–111
- [37] Nechita, E., Crișan, C., & Talmaciu, M. (2008). *Algoritmi paraleli și distribuiți*. Curs pentru studenții facultăților „Inginerie, specializarea Tehnologia Informației și Științe, specializarea Informatică.” <https://cadredidactice.ub.ro/simonavarlan/files/2012/02/curs-par-dis-completat.pdf>
- [38] Onyshkevych, B. (n.d.) Deep exploration and filtering of text (DEFT), Defense Advanced Research Projects Agency, US Department of Defense
- [39] *POS tags and part-of-speech tagging*. (2022, August 2). Sketch Engine. <https://www.sketchengine.eu/blog/pos-tags/>
- [40] Psotka, J. (1989). *Advancing the Mind/Machine Interface: Qualitative Simulations, Hypertext, and Natural Language Processing*. *Proceedings of the Human Factors Society Annual Meeting*, 33(19), 1334–1338. doi:10.1177/154193128903301921
- [41] Qin, X., Liu, J., Wang, Y., Liu, Y., Deng, K., Ma, Y., Zou, K., Li, L., & Sun, X. (2021). Natural language processing was effective in assisting rapid title and abstract screening when updating systematic reviews. *Journal of Clinical Epidemiology*, 133, 121–129. <https://doi.org/10.1016/j.jclinepi.2021.01.010>
- [42] Reiter, E., & Dale, R. (1997). Building applied natural language generation systems. *Natural Language Engineering*, 3, 57 - 87. doi: <https://doi.org/10.1017/S1351324997001502>
- [43] Sarkar, D. (2019). *Text Analytics with Python: A Practitioner’s Guide to Natural Language Processing* (2nd ed.). Apress.
- [44] Sberbank. (2017). *Sberbank and Moscow Institute of Physics and Technology sign strategic partnership agreement*. sberbank.com. <https://www.sberbank.com/ru/news-and-media/press-releases/article?newsID=03630750-5259-489c-8447-6623c7e91658>
- [45] Schirmer, P., Jaycocks, A., Mann, S., Marcellino, W., Matthews, J.D.P, Parsons, J.D., & Schulker, D. (2021) *Natural Language Processing: Security- and Defense-Related Lessons Learned*. Santa Monica, CA: RAND Corporation, 2021. <https://www.rand.org/pubs/perspectives/PEA926-1.html>.
- [46] Spangler, S., Wilkins, A. D., Bachman, B. J., Nagarajan, M., Dayaram, T., Haas, P., ... & Lichtarge, O. (2014, August). Automated hypothesis generation based on mining scientific literature. In *Proceedings of the 20th ACM SIGKDD international conference on Knowledge discovery and data mining* (pp. 1877-1886).

- [47] Suwanvecho, S., Suwanrusme, H., Jirakulaporn, T., Taechakraichana, N., Lungchukiet, P., Thanakarn, N., Decha, W., Boonpakdee, W., Preininger, A., Dankwa-Mullan, I., Solomon, M., Wang, S., Jackson, G., Patel, V., Shortliffe, E., & Kiatikajornthada, N. (2019). A blinded comparison of patient treatments to therapeutic options presented by an artificial intelligence-based clinical decision-support system. *Annals of Oncology*, 30, v583. <https://doi.org/10.1093/annonc/mdz257.030>
- [48] Tkachenko, N., & Guo, W. (2019) Conflict Detection in Linguistically Diverse Online Social Networks: a Russia-Ukraine Case Study. ACM International Conference on Management of Digital EcoSystems (MEDES). Polarisation on Online Communities (DSTL). doi <http://dx.doi.org/10.1145/3297662.3365819>
- [49] US Army Acquisition Support Center. (2022, November 16). Department of the Army Small Business Innovation Research (SBIR) Program SBIR 21.4 Broad Agency Announcement (BAA) Army Applied SBIR Opportunity (ASO) Announcement. *Sam. Gov.* <https://sam.gov/opp/a27caede2da442ce86ec6f52c2aa13f1/view#general>
- [50] van den Bosch, K., & Bronkhorst, A.W. (2018). Human-AI cooperation to benefit military decision making. *Proceedings of the NATO IST-160 Specialist' Meeting on Big Data and Artificial Intelligence for Military Decision Making, Bordeaux, F, 30 May-1 June 2018, S3-1/1 - S3-1/12.*
- [51] Wang, X., Chen, R., Jia, Y., & Zhou, B. (2013). Short Text Classification Using Wikipedia Concept Based Document Representation. *2013 International Conference on Information Technology and Applications*. <https://doi.org/10.1109/ita.2013.114>
- [52] Watson, H.J. (2017). Preparing for the Cognitive Generation of Decision Support. *Mis Quarterly Executive*, 16(3), 3.
- [53] Weinstein, C. J. (1991). *Opportunities for advanced speech processing in military computer-based systems*. Proceedings of the IEEE, 79(11), 1626–1641. doi:10.1109/5.118986
- [54] Wijermars, M., & Lehtisaari, K. (2021). Freedom of Expression in Russia's New Mediasphere. Taylor & Francis Limited.