

Izvorni članak UDK 159.925: 165.1: 179.9

Primljeno 29. 11. 2005.

Klaus Mainzer

Universität Augsburg, Lehrstuhl für Philosophie und Wissenschaftstheorie,
Universitätsstrasse 10, D-86159 Augsburg
klaus.mainzer@phil.uni-augsburg.de

Utjelovljeni um

O komputacijskim, evolucijskim i filozofskim tumačenjima spoznaje

Sažetak

Suvremenu kognitivnu znanost ne možemo razumjeti bez najnovijeg razvoja računalne znanosti, umjetne inteligencije (Artificial Intelligence – AI), robotike, neuroznanosti, biologije, lingvistike i psihologije. Kako klasična analitička filozofija, tako i tradicionalna AI pretpostavile su da sve vrste znanja moramo prikazati formalnim ili programskim jezicima. Ova je pretpostavka u proturječju s nedavnim uvidima u biologiju evolucije i razvojnu psihologiju ljudskog organizma. Većina je našega znanja implicitna i nesvjesna. To nije formalno prikazano, nego utjelovljeno znanje koje učimo radeći, a razumijevamo tjelesnim suodnosom s ekološkim nišama i društvenim okolišima. To vrijedi ne samo za vještine na niskoj razini nego i za visokorazinska područja kategorizacije, jezika i apstraktnoga mišljenja. Utjelovljena kognitivna znanost, AI, kao i robotika pokušavaju umjetnom evolucijom stvoriti utjelovljeni um. S filozofskoga gledišta, zapanjuje da tradicionalni pojmovi kognitivne znanosti i AI s formalnim predodžbama znanja pripadaju tradicionalnoj liniji filozofije.

Ključne riječi

spoznajna znanost, umjetna inteligencija, utjelovljeni um, računalna znanost, robotika, neuroznanost, lingvistika, psihologija

1. Klasična tumačenja spoznaje: umjetna inteligencija i filozofija uma

Na početku klasične kognitivne znanosti stoji Descartesov dualizam između uma i mozga, uma i izvanjskoga, tvarnoga svijeta. Prema Descartesu, ljudsko tijelo s mozgom jest materijalni stroj. Njime upravljaju urođene ideje (ideae innatae) koje ljudski um pohranjuje u mozgu na jasan i razgovijetan način (clare et distincte). Ljudski um (res cogitans) odvojen je od izvanjskoga svijeta (res extensa) u strogom spoznajnom dualizmu. Prepoznavanje je moguće pomoću izomorfno podudaranja između unutrašnjih predodžbi ideja i izvanjskih situacija i događaja. Kasnije je David Hume ovo kritizirao tako da niti u prirodi ne postoji uzročni mehanizam niti uzročni zakon u našem umu, nego samo nesvjesni refleks udruživanja osjetilnih dojmova (npr. bljesak munje i groma). Nema oštih i određenih pojmova koji bi se zasnivali na opažanjima, nego postoje samo više ili manje nejasni obrasci koji dopuštaju više ili manje vjerojatne tvrdnje glede slučajnih događaja.

U epistemologiji Immanuela Kanta prepoznavanje je aktivan proces, koji unutrašnje predodžbe svijeta konstruira pomoću apriornih kategorija. Tako se uzročna povezanost događaja ostvaruje zapravo pomoću kategorije uzročnosti u našem umu. Pojmovima upravljaju formalni obrasci (»Schema«).

Intuicija je moguća pomoću prostornog i vremenskog uređivanja događaja. Premda se temelji na osjetilnim podacima, izvanjski svijet subjektivna je konstrukcija čistoga uma. To je glavna poruka Kantova transcendentalnoga konstruktivizma suvremenoj kognitivnoj znanosti.

Daljnji važan korak kognitivne filozofije bila je fenomenologija svijesti Edmunda Husserla. Husserl pripada tradiciji kartezijanskoga kognitivizma, ali naglašava reprezentacijsku intencionalnost: da bismo opažali, djelovali i odnosili se prema predmetima, mora postojati neka unutarnja predodžba koja nam omogućuje upravititi svoj um prema svakome predmetu. U klasičnoj umjetnoj inteligenciji (AI) Husserlov intencionalni sadržaj svijesti odgovara formalnim reprezentacijama kompjutorskoga programa.

Kako su moguće formalne reprezentacije? S logičkog i matematičkoga gledišta Alan Turing definira kompjutor neovisno o svim tehničkim i fizičkim detaljima: Turingov stroj je formalni postupak koji se sastoji od: a) kontrolne kutije u kojoj se nalazi konačni program; b) potencijalno beskonačne vrpce, podijeljene po dužini na kvadrate; c) naprave za skeniranje ili štampanje na jednom kvadratu vrpce u vremenu, te za kretanje ili zaustavljanje duž vrpce, sve pod upravom kontrolne kutije. Turingov stroj može ostvariti svaki računalni postupak (algoritam) (Churchova teza). Univerzalni Turingov stroj može simulirati svaki Turingov program. U tehničkom pogledu, univerzalni Turingov stroj jest više ili manje opći namjenski kompjutor.

Na pozadini Turingove teorije komputabilnosti dobijamo njegov komputacijski kognitivizam koji pretpostavlja komputacijski funkcionalizam. Prema komputacijskom funkcionalizmu, mozak kao biološki *wetware* odgovara fizičkom hardveru računala. Um s pojmovima i logičkim zaključcima razumijevamo kao softver računalnog (Turingova) programa sa strukturama podataka i algoritmima. Turing zatim dokazuje ovako: ako je ljudski um komputabilan, možemo ga predočiti pomoću Turingova programa (Churchova teza) koji opet možemo izračunati pomoću univerzalnog Turingova stroja, naime tehnički, pomoću općeg namjenskog kompjutora. Turing i klasična umjetna inteligencija (AI) vjerovali su da je ljudski um komputabilan u smislu komputacijskog funkcionalizma. Slijedi tako da je um komputabilan pomoću općega namjenskoga kompjutora s dostatnom računalnom moći.

Čak i ako ljudi ne vjeruju u Turingovu jaku AI-postavku, oni često klasični komputacijski kognitivizam potvrđuju u sljedećem smislu: računalni procesi operiraju sa simboličkim predodžbama koje se odnose na situacije u izvanjskom svijetu. Te formalne predodžbe, zatim, trebale bi slijediti Tarskijevu korespondencijsku teoriju istine: zamislimo situaciju X u stvarnome svijetu (npr. nekoliko kutija na stolu) koju ukodiramo simboličkom predodžbom $A_1 = \text{ukodirati}(X)$ (npr. opis kutija na stolu). Ako se dekodira simbolička predodžba A_1 , onda dobijamo situaciju X_1 u stvarnome svijetu kao njezino značenje, tj. dekodirati $(A_1) = X_1$. Operacija T u stvarnome svijetu (ručno pokretanje kutija na stolu, primjerice) proizvelo bi isti rezultat A_2 u stvarnome svijetu, bilo da je učinjen u stvarnome svijetu ili na simboličkoj predodžbi:

$$\text{Dekodirati (ukodirati (T) (ukodirati (X_1)) = T (X_1) = X_2.}$$

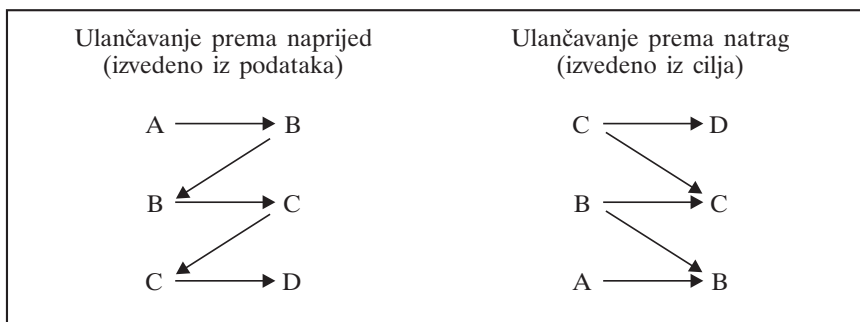
Nema, dakle, izomorfности između izvanjske situacije i njezine formalne predodžbe u kartezijanskoj tradiciji.

Komputacijski kognitivizam pretpostavlja da se strategije rješavanja problema mogu prikazati formalnim pravilima. Obično pravilo prometa traži:

AKO gori crveno, ONDA se promet zaustavlja. Možemo ukodirati pravilo s formalnim reprezentacijama A («gori crveno») i B («promet se zaustavlja») pomoću tzv. produkcijskoga pravila $A \rightarrow B$. Drugi primjer jest problem dijagnoze u medicini: AKO pacijent x ima srčani napadaj, ONDA x ima srčane enzime u krvi. Općenito možemo razlikovati problemske klase klasifikacije, dijagnoze, dizajna, planiranja te simulacije koje možemo prikazati formalnim AKO-ONDA ili produkcijskim pravilima $A \rightarrow B$:

Input	Problemske klase	Output
Podaci mjerenja, simptomi, itd.	Klasifikacija ili dijagnoza	Prepoznavanje pravilnosti/obrazaca
Ograničenja	Dizajn	Predmeti sa zadovoljavajućim svojstvima
Početno stanje, ciljano stanje	Planiranje	Slijed djelovanja koja početno stanje mijenjaju u ciljano
Početno stanje	Simulacija	Uzastopna stanja u budućnosti

Pravila se mogu kombinirati ulančavanjem prema naprijed (počinjući s podacima A te izvedeći cilj D) ili ulančavanjem prema natrag (počinjući s ciljem D te tražeći dostatne premise):



Ove metode rješavanja problema dobro su poznate iz filozofske tradicije, kao, primjerice, Papposove metode sinteze i analize, njihovo podrijetlo u aristotelovskoj logici, te njihov razvoj u filozofiji modernih vremena. Postoje također mnoge metode induktivne logike i probabilističkog zaključivanja, strategije dokazivanja ili opovrgavanja koje su uključene u ekspertne sustave zasnovane na znanju, no koje su međutim također dobro poznate i iz analitičke filozofije (Carnap, Quine, npr.) i filozofije znanosti (Popper, Lakatos, npr.).

Kao što je to istaknuo Clark Glymour (Fetzer, 1988: 195): umjetna inteligencija filozofsko je objašnjenje pretvoreno u kompjutorski program. Povijesno gledano, ono što smatramo umjetnom inteligencijom nastalo je preuzimanjem objašnjenja što su ih pružili filozofi i logičari, te pronalaženjem komputabilnih ekstenzija i njihovih primjena. Razvoji u programskoj tehnologiji težili su tome da proces transformiranja nekih vrsta filozofskih ob-

jašnjenja u programe učine skoro automatskim. Sustavi produkcijskih pravila eksploatiraju dvoznačnost između kondicionalnih iskaza i proceduralnih pravila, te dopuštaju da se teorije koje se sastoje od skupa kondicionala pretvore u jednostavan program. Većina filozofskih teorija upotrijebljenih u umjetnoj inteligenciji nije uzeta izravno iz filozofske literature, no to ih ne čini ništa manje filozofskima. Kompjutorska znanost poučava nas da kudikamo više toga pripada filozofiji nego što bismo to mogli i misliti: i umjetna inteligencija jest filozofija.

Ekspertni sustavi zasnovani na znanju nastoje predstaviti strategije rješavanja problema za odgovarajuće problemske klase. Suprotno konvencionalnim programima, ekspertni sustavi biraju odgovarajuća pravila automatski pomoću sustava zaključivanja s ulančavanjem prema naprijed ili prema natrag. Znanje je ključni čimbenik u izvedbi ekspertnog sustava koji simulira rješavanje problema od strane čovjeka stručnjaka, npr. znanstvenika ili fizičara u određenom području. Znanje je dvovrsno. Prvi tip jesu činjenice nekog područja zapisane u udžbenicima i časopisima toga područja. Jednako važan za praksu toga područja jest i drugi tip znanja, zvan heurističkim, što označava znanje dobre prakse i prosudbe u tome području. To je eksperimentalno znanje, umijeće dobra pogađanja što ga čovjek stručnjak stječe tijekom godina rada. Heurističko znanje najteže je zadobiti zato što stručnjaci rijetko posjeduju samosvijest kako bi prepoznali što ono jest. Zato interdisciplinarno obučeni inženjeri znanja moraju zadobiti pravila stručnjaka, prikazati ih u programskom jeziku i staviti ih u radni program. Ova sastavnica ekspertnog sustava naziva se stjecanjem znanja.

Postoji, međutim, još temeljniji problem kad je riječ o ekspertnim sustavima. Oni su ograničeni na specijaliziranu znanstvenu bazu bez svega pozadinskoga znanja čovjeka stručnjaka. Stručnjaci se ne oslanjaju na eksplicitne (deklarativne) reprezentacije zasnovane na pravilima, nego na intuiciju i implicitno (proceduralno) znanje. Jednostavan primjer iz svakidašnjeg života jest vožnja auta. Prve lekcije iz vožnje auta mogu se predočiti pomoću pravila i ulančavanja pravila u priručnicima. Nijedna situacija u stvarnome prometu, međutim, nije potpuno identična premisama priručničkoga pravila. Osim toga, da bismo upotrijebili tehničku opremu trebamo imati nešto osjećaja i senzitivnosti. Kako postati vješt u vožnji auta? Kao što svi znamo, to je moguće samo vježbanjem, praksom i iskustvom. Osim toga, pozadinski problem je filozofski izazov, kao što je to istaknuo Hubert Dreyfus (Dreyfus, 1979). Kako bi specijaliziranu znanstvenu bazu ekspertnog sustava trebalo kombinirati s generaliziranim i strukturaliziranim pozadinskim znanjem svijeta koji utječe na odluke i djelovanja čovjeka stručnjaka? U medicini, kad odlučuje o kirurgiji, dobar će liječnik također uzeti u obzir i objektivne dojmове koje ima glede pacijentovih životnih uvjeta (obitelj, posao itd.) i njegova/njezina stava prema životu. Isti aspekt možemo pokazati i u ekspertnim sustavima zakona. Usprkos svim konzistentnim sustavima pravila, sudac će na kraju pronaći formalan cilj za moguće odluke, pri čemu će se orijentirati prema svom osobnom pogledu na svijet i život. Odvjetnici zaista koriste hermeneutičke metode tumačeći tekst zakona, kako bi došli do odluka u skladu s formalnim zakonom i materijalnim aspektima stavova i nakana.

Zbog sve složenijih situacija, na pravilu zasnovane reprezentacije raspadaju se na najrazličitija pravila i korisnik gubi bilo kakav pregled nad njima. Tako je Marvin Minsky pokušao poboljšati reprezentaciju znanja uvođenjem

okvira. Oni su formalne reprezentacije predmeta i situacija, i sastoje se od formalnih varijabli za obilježja (zvana *slots*) i stvarne vrijednosti (zване *fillers*):

Predmet	Obilježje	Vrijednost
Zebra	je	sisavac
	boje	prugaste
	ima	kopita
	duga je	1,2–1,8 m
	živi	u Africi

Filozofijski, okviri se smatraju kognitivnim shemama kategorija, organizirajući naše znanje predmeta i situacija s unutrašnjim reprezentacijama. Kao što sam prije spomenuo, one igraju temeljnu ulogu u Kantovoj epistemologiji. Očito je da se mogu zamijeniti i logičkim pravilima: npr., AKO je x zebra, ONDA je x prugast; AKO je x zebra, ONDA x ima kopita; itd. Okviri, međutim, povezani pojam skupljaju i uređuju na intuitivan način u grafičku shemu, umjesto u beskonačan niz nepovezanih pravila. Popisi su formalne reprezentacije o vremenu ovisnih procesa, s preduvjetima, predmetima i rezultatom. Scene predstavljaju statične situacije i događaje. Slijed scena predstavlja kauzalni lanac događaja. Primjer je iz svakodnevnog života restoranski popis Rogera Schanka, s tipičnim scenama u američkom restoranu:

Restoranski popis		
Uloge		mušterija (m), konobar (k), šef (š), vlasnik (v)
Predmeti		stolovi, stolice, meniji, hrana, računi, novac, napojnica
Preduvjet		m ima novaca, m je gladan
Rezultati		m ima manje novaca, v ima više novaca, m je manje gladan
Scena 1	ULAZAK	m ulazi u restoran
Scena 2	SJEDANJE	m čeka da sjedne, m uzima stolicu, m sjeda
Scena 3	NARUČIVANJE	m traži menu, proučava ga i naručuje jelo od k
Scena 4	OBJED	k donosi hranu, m je jede
Scena 5	PLAĆANJE	m traži od k račun, m plaća račun, m ostavlja napojnicu
Scena 6	ODLAZAK	m napušta restoran

Nakon primjera ovih reprezentacija, postavlja se pitanje može li se razumijevanje uopće svesti na formalna pravila. John Searle objasnio je ovaj problem svojim poznatim misaonim eksperimentom »kineske sobe«: koris-

teći samo sintaktička pravila simbola, on ili kompjutor daju odgovore na kineska pitanja napisana na karticama koje su u sobu predane kroz prozor. Premda on ili kompjutor ne razumiju kineski, on ili kompjutor mogu proizvesti znakovite kineske iskaze pomoću formalnih pravila kineskih znakova. Naravno da je Searleov misaoni eksperiment pretjerivanje, zato što nam je i za samo korištenje formalnih pravila potrebno proceduralno znanje. No, svi znamo da se strani jezik ne uči proučavanjem formalne gramatike i simbola, nego poglavito razgovorom i komunikacijom, naime učeći kroz provedbu i proširivanjem implicitnog (proceduralnog) znanja jezika. Ukratko: reprezentacija lingvističke kompetencije, zasnovana na pravilu, jest ograničena.

Kao što je znao već i Wittgenstein, naše razumijevanje jezika ovisi o situacijama. Situiranost reprezentacija težak je problem primijenjene robotike. Klasičan robot treba potpunu simboličku reprezentaciju situacije koja se mora ažurirati ako se promijeni položaj robota. Primjerice: robot kruži oko stola na kojem su lopta i šalica. Formalna reprezentacija u kompjutorskom jeziku može biti NA (STOLU, LOPTI), NA (STOLU, ŠALICI), IZA (ŠALICE, LOPTE), itd. Ovisno o položaju robota s obzirom na raspored, šalica je nekad iza lopte, a nekad nije. Formalna reprezentacija IZA (ŠALICE, LOPTE) mora se stoga ažurirati uvijek s promjenom položaja. Kako robot može spriječiti nepotpuno znanje? Kako može razlikovati između stvarnosti i njezine dotične perspektive? Situirani agenti poput ljudi ne trebaju nikakvih reprezentacija ni ažuriranja. Oni gledaju, govore i međusobno djeluju tjelesno, naime pokazujući na stvari. Čak i racionalno djelovanje u iznenadnim situacijama ne ovisi o unutrašnjim reprezentacijama i logičkim zaključivanjima, nego o tjelesnim interakcijama unutar situacije (npr. gledanju, osjećanju, reagiranju). Zamislimo dječaka na biciklu koji iznenada zaokrene kako bi izbjegao maloga puža na cesti. S druge strane, racionalne misli s unutrašnjim reprezentacijama ne jamče racionalno djelovanje: profesor logike može pogriješiti u mnogim praktičnim situacijama, zato što su složene stvarne situacije dosta daleko od više ili manje pojednostavnjenih formalnih reprezentacija.

Razlikujemo stoga formalno i utjelovljeno djelovanje u igrama koje su više ili manje nalik stvarnom životu; šah, primjerice, jest formalna igra s kompletnim reprezentacijama, strogo definiranim stanjima, pozicijama na ploči te formalnim operacijama. Kockanje je neformalna igra s vještinama koje ovise o tjelesnim interakcijama, bez potpunih reprezentacija situacija i operacija koje nikad nisu posve identične – kao naš život, samo daleko jednostavnije. Prema Mauriceu Merleau-Pontyju, intencionalne ljudske vještine ne trebaju nikakvu unutrašnju reprezentaciju, nego se one treniraju i uče, te su utjelovljene u optimalnom »gestaltu« koji se ne može ponoviti. Atletičar poput skakača s motkom ne može ponoviti svoj uspješan skok kao stroj koji stvara isti rezultat. Merleau-Ponty tako ističe:

»Pokrenuti nečije tijelo znači ciljati na stvari kroz njega; to znači dopustiti nekome da odgovori na njihov zov, upravljen tome tijelu neovisno o bilo kakvoj reprezentaciji.« (Merleau-Ponty, 1962: 139)

Husserlova reprezentacijska intencionalnost zamjenjuje se intencionalnošću zasnovanom na tijelu.

2. Umjetna evolucija i utjelovljena spoznaja

Tjelesno zasnovana intencionalnost čudesna je kad zdravi organizam djeluje bez svjesne kontrole, no to nije tajna. Moderna biologija i neurološke

znanosti pružaju mnoge uvide u njezino podrijetlo tijekom životne evolucije. Ključni pojam jest samo-organizacija. U pred-biotičkoj evoluciji, samo-sakupljajući molekularni sustavi postaju osposobljenima za samo-ponavljanje, metabolizam, te mutaciju u danoj skupini planetarnih uvjeta. Molekularna informacija tih obilježja pohranjena je u molekularnim komponentama. Za biokemiju je još uvijek izazov pronaći molekularne programe generiranja života iz »mrtve« tvari. Darwinovo evolucijsko stablo zemaljskih vrsta može se objasniti genetičkim programiranjem DNA-kodova. Mutacije su slučajne promjene DNA-kodova, te dovode do razdvajanja na evolucijskom stablu. Selekcije su pokretne sile. Evolucija nervnih sustava i mozga utjelovljena je u evolucijskom stablu vrste kao novi vid informacijskog procesa. DNA-kod jest fiksni program koji se većinom ne mijenja tijekom životnog vijeka organizma. Jedino njegova populacija može naučiti mijenjati ponašanje odabirom prototipova s promijenjenim DNA-kodovima bolje adaptiranim na neke ekološke niše u sljedećim naraštajima.

Mozgovi su neurološki sustavi koji dopuštaju brzu prilagodbu na promijenjene situacije tijekom životnoga vijeka organizma. Ukratko: oni mogu učiti. Ljudski mozak složen je sustav neurona koji se samoorganiziraju u makroskopskim obrascima pomoću neurokemijskih interakcija. Percepcije, emocije, misli i svijet odgovaraju tim neurološkim obrascima. Samo-organizacija spoznaje rasvjetljuje se obaveznim problemom vizualne percepcije. Kako je moguće našem vizualnom sustavu prepoznati dotični *gestalt* (oblik), a ne samo skup obojenih piksela? U samo-organizirajućem procesu učenja mozak odgovara na različite *stimuli* s različitim nakupinama sinkrono izgarajućih neurona. Te stanične nakupine kodiraju povezivanje pojedinih obilježja u opažajnom predmetu pomoću sinkronih neuroloških aktivnosti. Pravila njihova učenja otkrio je Donald O. Hebb, a nedavno su ih potvrdili Wolf Singer i dr. U nešto starijoj teoriji Barlow je pretpostavio da svako obilježje nekoga predmeta mora predstaviti specijaliziranim neuronima. Da bi ih povezao u oblik, on je uveo tzv. stanice-majke. Za još složenije reprezentacije, njemu je potreban rastući broj neurona (»stanice-bake«) koje predstavljaju hijerarhije povezanih obilježja, povezanih skupina obilježja, itd., koje iskustveno bivaju odbačenima promatranjem mozgovnih aktivnosti.

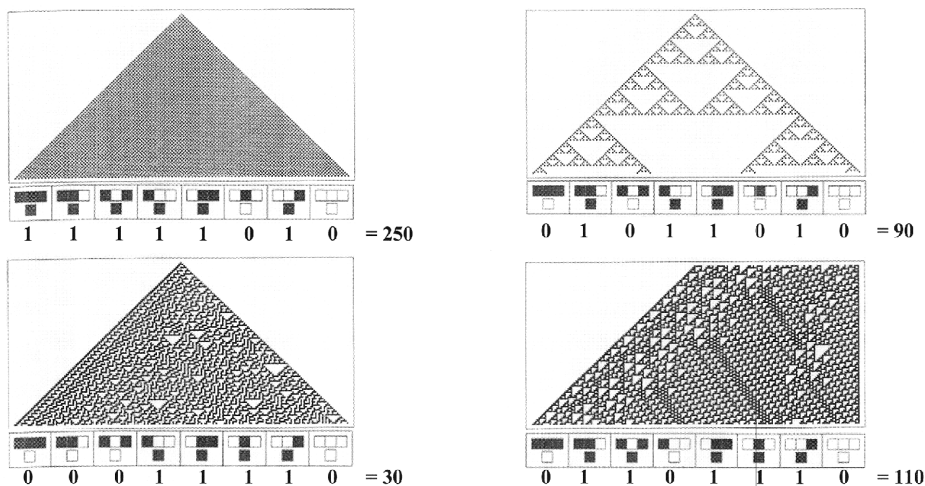
U središnjem živčanom sustavu, milijuni nervnih stanica organiziraju složen signal i komunikacijski proces ljudskoga tijela. Izgaranje i ne-izgaranje neurona proizvode gust tijek binarnih signala koje dekodira mozak. Nakon DNA-kodova i mozga koji uče, sljedeći korak staničnog informacijskog procesa čine učeće populacije. U sociobiologiji, populacije jednostavnih insekata poput mravi organiziraju složen transport, signal i komunikaciju pomoću inteligencije jata. Nema središnjeg nadzornika. Poredak sustava jest samo-organizirajući u skladu s kemijskim signalima među tisućama životinja. Populacije s inteligencijom jata kadšto nazivamo superorganizmima ili čak supermozgovima. U stvarnosti, populacije, vrste i društva nisu samo skupine izoliranih mozga, organizama ili ljudi, nego su to nove vrste samo-organizirajućih sustava.

Sve ove stepenice prirodne evolucije postale su više ili manje planovima za računanje i informacijske sustave u umjetnoj ko-evoluciji tehnologije. Podsjećam čitatelja na kvantnu fiziku s elementarnim česticama i atomima, koja danas pruža standarde za kvantno računanje; nano-tehnologija za molekularno računanje; genotehnologija za DNA-računanje, evolucijska biologija za evolucijske algoritme u bioračunanju; istraživanje mozga za neuroračunanje nervnih mreža; kognitivna znanost za podatno računanje s nejasnom

logikom, učenjem algoritama i afektivnim računanjem, te, ne na kraju, sociobiologija i sociologija za socioniku s raspodijeljenom Umjetnom Inteligencijom i sustavima multi-agenata. Pogledajmo na neke od ovih koraka u umjetnoj evoluciji.

S filozofske točke gledišta, već je Gottfried Wilhelm Leibniz krajem 17. stoljeća ustvrdio kako život možemo smatrati složenim automatima: »svako organsko tijelo živoga bića«, kaže on u svojoj *Monadologiji* (§ 6), »jest neka vrsta božanskoga stroja ili prirodnog automata koji beskonačno nadmašuje sve umjetne automate.« Danas se njegovo gledište pretresa kao načelo komputacijske ekvivalencije koja zahtijeva da za svaki prirodni sustav postoji odgovarajući komputacijski sustav. Leibnizovu metafizičku ideju stroja pojasnio je krajem 50-ih godina prošloga stoljeća John von Neumann pomoću staničnih automata. Stanični automati složeni su sustavi konačnih automata koje možemo ilustrirati stanicama na ispreprtanoj mreži sa stanjima naznačenima brojevima ili bojama. U binarnom slučaju postoje samo dva stanja 0 i 1, ili bijelo i crno. Stanice mijenjaju svoja stanja ovisno o susjednim stanicama u skladu s jednostavnim lokalnim pravilima. Ponavljam, ne postoji središnji procesor, nego samo-organizacija. Specijalni stanični automati mogu se reproducirati u uzastopnim naraštajima kao živi organizmi. Svaki kompjutor može se simulirati odgovarajućim staničnim automatom (SA), te obrnuto. Postoje univerzalni SA koji mogu simulirati bilo koji posebni SA poput univerzalnog Turingova stroja.

Glavna poruka SA jest sljedeća: s jednostavnim pravilima razumljivima bilo kojem učeniku stanični automati mogu generirati sve vrste složenih struktura u prirodi. Razmatramo, primjerice, 1-dimenzionalne automate s dvama stanjima, koji se razvijaju crtu po crtu od početnog stanja na vrhu mreže. Svaka aplikacija pravila ovisi o stanjima triju prethodnih stanica. Tako je svaki automat karakteriziran pomoću $2^3=8$ pravila. Njihovih osam binarnih outputa mogu se dekodirati odgovarajućim decimalnim brojem kao »DNA-kod« umjetnog organizma. Oni mogu generirati potpuno pravilne i simetrične obrasce poput kristala, ali i potpuno nepravilne i slučajne obrasce bez ikakve strukture (lijevo dolje) poput pahuljica snijega u oluji ili lokalno korelirane složene obrasce (dolje desno) poput organskih struktura u prirodi:



Sve više različitih složenih i slučajnih obrazaca može se generirati pomoću istoga jednostavnog pravila staničnih automata s različitim početnim uvjeti-

ma. U mnogim slučajevima ne postoji konačan program kako bi se predvidio razvoj slučajnih obrazaca. U tom se slučaju proces razvoja ne može potisnuti, i to zbog komputacijske nesvodivosti. Želimo li znati budućnost, moramo čekati i promatrati aktualni razvoj. Ovi uvidi staničnih automata imaju izvanredne posljedice u znanosti i filozofiji. Znanstvenici su u prošlosti vjerovali kako nam poznavanje zakona omogućuje izračun dinamičnog sustava. Stanični automati nam pak pokazuju: čak i ako znademo sva interaktivna pravila elementarnih čestica i atoma u fizici, molekula u kemiji, stanica u biologiji, te živaca u istraživanju mozga, nismo nužno kadri i izračunati dinamiku njihovih složenih sustava. Prema načelu komputacijske korespondencije, složeni atomski, molekularni ili stanični sustavi jesu komputacijski, ali nisu nužno i izračunljivi.

U sljedećem koraku umjetne evolucije, razmatramo neuronske mreže koje rade poput mozгова s prikladnim topologijama i učenjem algoritama. Neuronske su mreže složeni sustavi tehničkih neurona, aktivni (»izgarajućih«) i ne-aktivnih (»neizgarajućih«), ovisno o nekim pragovima poput bioloških neurona. Neurokemijske interakcije između bioloških neurona simuliraju se pomoću numeričkih veličina koje označavaju stupanj povezanosti. Ne postoji, ponavljam, nikakav središnji procesor, nikakva »stanica majka«, nikakva misleća ili osjećajuća stanica, nego samo-organizirajući tijek informacija u nakupinama stanica u skladu s pravilima sinaptičkih interakcija (Hebbova pravila unatragne propagacije, primjerice). Neuronske mreže pokušavaju simulirati sinaptičku plastičnost živućih mozgov a s njihovom tolerancijom prema pogreškama, te samo-prilagodbom na promijenjene situacije. Učenje algoritama može se nadgledati kao što učitelj nadgleda učenje. U tom slučaju oni poboljšavaju svoje rezultate uspoređujući ih s nekim prototipovima (npr. prepoznavanjem pohranjenih obrazaca). Oni također mogu biti i ne-nadgledani, nalazeći nove obrasce, skupine ili pojmove metodom pokušaja-pogreške, te evolucijskim postupcima selekcije.

Utjelovljenost neuronskih mreža jest cilj utjelovljene robotike: jednostavan robot s motornom opremom (npr. kotačima) i različitim sensorima koji pokazuju blizinu objekata, izvore svjetla, te sudaranje s preprekama može generirati složeno ponašanje pomoću samo-organizirajućih neuronskih mreža. Utjelovljena neuronska mreža, primjerice, ima slojeve neurona za motorna djelovanja (npr. zaokretanje, kretanje prema naprijed) te za senzore blizine ili sudara. U slučaju sudara, povezanosti između aktivnih neurona blizinskog sloja i sloja sudara pojačavaju se Hebbovim učenjem: javlja se obrazac ponašanja kako bi izbjegao sudare u budućnosti. To je primjer pre-racionalne inteligencije.

U prirodi, središnji procesor također ne izračunava niti kontrolira složene obrasce kretanja, nego to čini samo-organizirajuće učenje algoritama neuronskih mreža. Primjer je skakavac sa šest nogu, što ga je nedavno simulirao mali robot na Tehničkom fakultetu u Münchenu. Za svaku nogu postoje tri modula kretanja, poput penjanja, njihanja, te koordiniranja dijelova za penjanje i njihanje. Motorno znanje uči se u nepoznatom okolišu i biva pohranjeno implicitno raspodjelom sinaptičkih veličina u mrežama. Tijekom evolucije decentralizirani moduli imali su veliku prednost, zato što su se mogli upotrijebiti kao građevni blokovi za različite organizme u budućim razvojjima. U ljudskom organizmu, šetanje je složena tjelesna samo-organizacija, uglavnom bez središnje kontrole mozga i svijesti: motorna inteligencija javlja se bez unutarnjih reprezentacija. Jednostavan robot Sveučilišta u Illinoisu vrlo prirodno i poput čovjeka šeta niz kosinu i pokreću ga samo interakcija okolnog sustava, inercija, te sudar, prije negoli kakav unutrašnji središnji

kontrolor. To je složen dinamički sustav koji u ravnotežu ograničenoga kruga tjera jako periodičko kretanje.

Iz složene tjelesne interakcije s okolišem – pomoću senzorno-motorne koordinacije bez unutarnje reprezentacije – javljaju se ne samo motorna inteligencija »niske razine« nego i spoznaja (npr. kategorizacija) »visoke razine«. Zovemo je »utjelovljenom spoznajom«: dijete uči kategorizirati predmete i graditi pojmove dodirivanjem, hvatanjem, manipuliranjem, osjećanjem, kušanjem, slušanjem, te gledanjem stvari, a ne pomoću eksplicitnih reprezentacija. Kategorije su nejasne i mogu se poboljšati i mijenjati tijekom života (u Humeovu smislu). Djeca, međutim, imaju urođenu sklonost konstruirati i primjenjivati konceptualne sheme i oruđa (u Kantovu smislu). Pojavu utjelovljene spoznaje istaknuo je već i John Dewey:

»Mi ne započinjemo sa senzornim stimulusom, nego sa senzomotornom koordinacijom... (U nekom smislu upravo je kretanje primarno, a osjetilnost sekundarna; kretanje tijela, glave i oka koje određuje ono što iskustveno doživljavamo.« (Dewey, 1896/1981: 127)

Utjelovljena spoznaja cilj je utjelovljene robotike. Razmotrimo sljedeći primjer (Pfeifer/Scheier, 2001: 428): robot s vizualnim, haptičkim i motornim sustavima (npr. kamerom, hvataljkom i kotačima) ima zadaću skupiti neke predmete i donijeti ih kući, u bazu. On, dakle, mora kategorizirati konduktivne i ne-konduktivne predmete s jako ili neznatno hrapavim površinama. Senzorne mreže primaju inpute od senzora. Ove senzorne mreže povezane su na pozornost i mape obilježja odgovarajućih mreža, koje zajedno s efektorima tvore pozornosnu senzorno-motornu petlju, moduliranu pomoću mape vrijednosti u skladu s robotovom zadaćom. Vrijednosti predstavljaju nakane i motivacije robota.

Neurološke mreže mogu čak simulirati kognitivne sposobnosti visoke razine poput govora. Mreža poput NET-govora uči govoriti poput djeteta čitajući sve više i više nepoznate tekstove, te poboljšavajući njihov izgovor uspoređujući ga s proučenim primjerom dobro poznatog teksta (nadzirano učenje s unutrašnjom propagacijom). Izgovor ne biva predstavljen pomoću pravila, nego je raspodijeljen u sinaptičkim veličinama izgaranja staničnih nakupina sa sličnošću odgovarajućim mozgovnim aktivnostima. Mreže su uspješne u prepoznavanju obrasca. Njihova sinaptička plastičnost dopušta prepoznati primjere proučenih prototipova, čak i ako su nejasni i bučni u nekom intervalu tolerancije poput ljudskih mozgova. Prepoznavanje obrasca primjenjuje se na emocionalno računanje. Japanski robot po imenu Mark II prepoznaje emocionalne izraze ljudskoga lica (npr. sreću, ljutnju, agresiju, iznenađenje) s prepoznavanjem obrasca neuronske mreže, te reagira oblikujući prikladan izraz lica u pravo vrijeme. To je primjer ne-verbalne komunikacije.

U tehnologiji čipa, analogne i digitalne mreže integrirane su u staničnim neuronskim mrežama kao u ljudskom živčanom sustavu. Stanične neuronske mreže (SNM) kombiniraju ustrojstvo staničnih automata (SA) sa sposobnostima za učenje neuronskih mreža. One tako mogu generirati sve vrste složenih obrazaca SA (formacija obrasca), ali ne mogu prepoznati i obrasce poput neuronskih mreža (prepoznavanje obrasca). SNM se primjenjuju kao čipovi visoke brzine u vizualnom računarstvu i robotici. U prepoznavanju obrasca javlja se problem: kako za žive mozgove tako i za umjetne mreže. SNM prepoznaje globalno povezane obrasce i razlikuje nepovezane dijelove. U tzv. »gestalt psihologiji« prošloga stoljeća ljudi su sumnjali da li bi uopće bilo moguće simulirati prepoznavanje »holističkoga« gestalt-a (oblika) pomoću »mehaničkih« obrazaca. SNM su to učinile. Drugi problem »gestalt psihologije« jest dobro poznata vizualna iluzija dvaju si-

metričnih lica ili vaza. »Gestalt psiholozi« tvrdili su da se iznenadno skretanje između dvaju holističkih oblika, bilo dvaju simetričnih lica ili vaze, nikako ne bi moglo ostvariti mehaničkim postupcima. U ljudskom prepoznavanju, preferiranje jedne od tih dviju mogućnosti ovisi o početnoj pozornosti za slučajni detalj, bilo u prednjem planu ili na pozadini slike. Na isti način SNM-čip simulira prepoznavanje obrasca iluzije lica-vaze, ovisno o procjeni nekih piksela u prednjem planu ili pozadini. Kao SNM djelo sa snažnom paralelnom moću računanja i univerzalnim računanjem poput univerzalnih staničnih automata, oni se mogu primijeniti i u neurobionici i high-tech medicini: električna aktivnost mozga (npr. EEG signali) bilježi se iz elektroda kako bi se otkrili obrasci prijeteće bolesti (npr. epilepsije), te kako bi se ojačala prikladna medicinska prevencija (npr. infuzija droge).

U našem filozofskom kontekstu neuronski kompjutori čine realističnijim misaoni pokus što ga je prije dva stoljeća uveo Hilary Putnam kao slikoviti prozor horra (Putnam, 1981: 21). Pretpostavimo da postoji izolirani kartezijanski mozak uklonjen iz svoga tijela i uronjen u hranjivu tekućinu u posudi. Dolazni živčani završeci povezani su sa super neuronskim kompjutorom (npr. SNM-čip) koji proizvodi sve senzorne inpute mozga. Može li se mozak sam odlučiti za tvrdnju »ja sam mozak u posudi«? Istjelovljeni mozak ne može: pojmovi kao »mozak«, »posuda«, itd. ne odnose se na realne stvari, nego na unutrašnje reprezentacije virtualne stvarnosti što ih stvara neuronski kompjutor. Čak i samo-iskustvo vlastita mozga u smislu Descartesova »cogito« treba tijelo i tjelesne interakcije: »Sum, ergo cogito.«

U nedavnom filmu Steven Spielberg ilustrira mogućnost da su sve naše misli determinirane i proračunljive. U njegovu *Minority Report*, posebna politička agencija kadra je predvidjeti buduće misli ljudi, e da bi spriječila buduće zločine. Gubitak slobodne volje imao bi nemjerljive posljedice za naše zakone i društva. Ljudi u biti ne bi bili odgovorni za svoje odluke i radnje. Njihovo ponašanje određivala bi genetika i neuronske sklonosti. Zločin bi bio problem medicine i softverskog inženjeringa. Odvjetnike i učitelje zamijenili bi liječnici, genetički i nervni inženjeri. Misli i emocije očito odgovaraju složenim obrascima neuronskih staničnih nakupnina, generiranih jednostavnim sinaptičkim pravilima nervnih interakcija (npr. Hebbova pravila učenja). Istraživači mozga tako pretpostavljaju da su mozgovni procesi determinirani i izračunljivi, zato što su dobro poznati njihovi zakoni nervne interaktivnosti. Oni dokazuju na pozadini školske fizike: buduća je putanja planeta izračunljiva, zato što poznajemo Keplerov deterministički zakon. No, čak i u slučaju planetarnog sustava moramo uzeti u obzir problem mnogih tijela nekoliko interaktivnih planeta sa suncem, što dovodi do nestabilnosti, pa čak i kaosa koji priječi dugoročna predviđanja, premda su fizikalni zakoni deterministički i dobro poznati. Formacija obrasca staničnih automata pokazuje da globalno ponašanje staničnih interakcija može biti suviše složeno da bi ga u detalju mogao predvidjeti konačan program, iako su lokalna pravila interaktivnih stanica jednostavna i dobro poznata.

Ljudski mozak ima problem mnogih tijela od 10^{11} neurona s 10^{14} sinaptičkih interakcija. Tako, prema načelu komputacijske korespondencije, mozak je komputacijski sustav, ali ne i izračunljiv. U biti, čvrste lokalne interakcije neurona proizvode globalnu slučajnu buku s otocima strukturnih obrazaca (atraktora) koji predstavljaju naše misli, opažanja, osjećaje, svijest i motorne aktivnosti. Mozak stoga ima stohastičku dinamiku, pa u najboljem slučaju možemo tek otkriti neke strukturne obrasce, te kratkoročno izračunati neke buduće trendove poput oblaka i njihova budućeg razvoja u vre-

menskoj prognozi. Stohastička dinamika čini slobodnu volju u najmanju ruku mogućom.

3. Globalna umreženost i utjelovljena spoznaja

Vrsta, stanovništvo ili društvo nisu samo zbroj njihovih pojedinačnih mozgova ili tijela nego, također, nova vrsta superorganizma ili supermozga stvorena međudjelovanjem njihovih pojedinaca koji međusobno komuniciraju. Nakon sustava prirodne evolucije prijenosa obavijesti i komunikacije (o kojima smo raspravljali u prvom poglavlju), u tehničkoj ko-evoluciji javljaju se mreže globalne komunikacije iznenađujuće slične samo-organizirajućim neuronskim mrežama ljudskoga mozga. Poput neuronskih impulsa u živčanom sustavu, promet podataka jest informacijska bujica na Internetu, konstruirana pomoću paketa podataka s izvorom i određivim adresama. Rute (poruke) su čvorovi mreže koji određuju lokalni put svakoga paketa, koristeći lokalne tablice ruta (poruka) s cjenikom za susjedne rute (poruke). Jedna ruta (poruka) upućuje svaki paket do susjedne uz najnižu cijenu. Aktivnosti slanja i ponovnog slanja poruka mogu dovesti do zagušenosti i kaosa. Možemo primijetiti složene obrasce visoke, srednje i niske gustoće prometa podataka, slične obrascima nervnih aktivnosti u mozgu.

Komputacijske i informacijske mreže postale su tehničkim superorganizmima koji se razvijaju u kvazi-evolucijski proces. Kompjutorske mreže su komputacijske ekologije. Budući da je Internet visoko složena informacijska mreža, u kaotičnim situacijama moramo upravljati tijekom informacija tako da te iste gubimo. »Izgubljeno na mreži« jest popularni slogan tih problema što postaju sve složenijima. Struja informacija na više ili manje kaotičnom Internetu izazov je za inteligentno pronalaženje informacija. U skladu sa sinaptičkom plastičnošću mozga, nalaženje informacija trebalo bi biti optimalno pomoću soft kompjutorstva. Nalaženje Informacija (NI) na Internetu zahtijeva odlučne postupke da bi se procijenilo i selektiralo relevantne dokumente u skladu s nekim ograničenjima. U binarnoj (Booleovskoj) logici, dokument je ili relevantan (1) ili nije (0) za informacijsko pretraživanje. U biti, dokument više ili manje odgovara našim interesima. (Soft) ograničenja tipična su za ljudske odluke i proces obrade informacija. U nejasnoj logici on ima stupanj relevancije u intervalu (0,1), ovisno o profilu i sklonostima korisnika.

Daljnje primjene (soft) računarstva su genetički algoritmi, kako bi se poboljšalo nalaženje informacija. U prirodnoj evoluciji genetički algoritmi reprodukcijom, mutacijom i selekcijom optimiziraju populacije kromozoma u slijedećim naraštajima. U nalaženju informacije oni se primijenjuju za optimizirajuće pretrage dokumenata. Kromozom je sekvencija dokumenata koji su obilježeni važnim ključnim terminima u binarnim kodovima. Populacije su skupine kromozoma. Mutacija označava slučajnu promjenu binarnih brojaka. Sekvencijalni binarni kodovi mogu se rekombinirati. Stupnjevi podudaranja mjere relevantnost dokumenata. Selekcija je procjena populacija dokumenata.

Promatrati Internet kao neku vrstu supermozga sa samo-organizirajućim obilježjima učenja i adaptiranja ne znači tek metaforu. Analogije s mozgom mogli bismo upotrijebiti kao heuristička sredstva za upravljanje tijekom informacija na Internetu. Nalaženje informacija ostvaruje se već pomoću neuronskih mreža koje se adaptiraju na informacijske sklonosti ljudskih korisnika sa sinaptičkom plastičnošću. Višeslojne neuronske mreže mogu se primijeniti za optimizirajuće pretrage dokumenata. Sinaptički spojevi (»težine«)

među neuronima mijenjaju se u skladu s učenjem algoritama. Relevantnost termina u dokumentu odgovara težinama među neuronima termina i dokumenata. Neuroni izgaraju ako zbroj težišnih inputa premašuje kritični prag. Učenje algoritma pruža rezultat prve pretrage pomoću propagacije. Devijacije korisnikovih sklonosti opterećuju se i šire natrag do termina i sloja inputa (»unatrazna propagacija«), te poboljšavaju tijekom nekoliko ponavljanja.

Od populacija mrava i termita možemo u sociobiologiji učiti kako pomoću inteligencije jata organizirati promet i obradu informacija. S tehničke točke gledišta, potrebni su nam inteligentni programi raspodijeljeni u mreže. Postoje već više ili manje inteligentni virtualni organizmi (agenti), koji uče, koji se samo-organiziraju i adaptiraju na naše individualne sklonosti za informaciju – to da biramo svoje e-mailove, obavljamo ekonomske transakcije ili da se branimo protiv napada neprijateljskih kompjutorskih virusa, kao obrambeni sustav našega tijela. Virtualni agenti dizajnirani su s različitim stupnjevima autonomije, pokretljivosti, reaktivnosti ili sposobnostima učenja komunikacije. Sa svojim virtualnim okolišom oni komuniciraju i sudjeluju kao lokalno područje utjecaja.

Ima i stacionarnih agenata koji svoju dužnost vrše smješteni u specijalnim serverima ili mobilnim agentima koji se na World Wide Web mogu poslati kao *byte* kodovi i koji svoju zadaću obavljaju bez povezivanja klijenta ili servera *on-line*. E-trgovina izazov je za istraživanje složenosti koje se može izvesti jedino uz pomoć virtualnih agenata koji podupiru ekonomske transakcije. U budućnosti, genetički algoritmi omogućit će nam da uzgajamo populacije agenata u složenoj evoluciji virtualnog života. Populacije agenata mogu se reproducirati genetičkim algoritmima kako bi optimizirale svoje pronalaznje informacija u skladu s korisnikovim pretragama. Agenti započinju s profilom korisnika. Oni opterećuju relevantnost dokumenta, i to određujući udaljenost (broj linkova) između ključnih riječi dokumenta i ključnih riječi pretrage. »Energija života« agenta povećava se ili smanjuje prema uspjehu ili neuspjehu njegove pretrage. Selektiraju se uspješni agenti, mijenjaju svoj genotip, te se reproduciraju.

Agenti komuniciraju s tipovima govornih akata kompjutorskog jezika JZPM (Jezik Znanja, Pretrage i Manipulacije). Govorni akti su dizajnirani kao intencije, u skladu s filozofijom jezika Johna L. Austina i Johna Searlea:

Performativni tip govornog akta	Značenje
Postići	S želi da R napravi istinitu tvrdnju u svome okolišu
Oglasiti	S je posebice kvalificiran za izvršenje tipa govornog akta
Pitati-sve	S želi primiti sve odgovore iz R-ove baze znanja
Pitati-jednoga	S želi primiti jedan odgovor iz R-ove baze znanja
Posrednik-jedan	S želi da R nađe pomoć za odgovor na govorni akt
Zanijekati	Govorni akt više nije istinit za S
Prebrisati	S želi da R prebriše neke činjenice iz svoje baze znanja
Preporučiti-jedan	S želi dobiti ime agenta koji može odgovoriti na govorni akt
Regrutirati-jedan	S želi da R regrutira agenta koji će izvršiti govorni akt
Žal	S ne posjeduje potrebno znanje ili informaciju
Potpis	S želi neprekinutu informaciju ili R-ov odgovor na govorni akt
Reći	S šalje informaciju

Poput ljudskih bića, umjetni agenti mogu izražavati svoje nakane pomoću jezika te inicirati reakciju svojega komunikacijskog partnera. To je druga važna primjena filozofskoga pojma u računalnoj znanosti.

U afektivnom računalstvu agenti su opremljeni softverom koji simulira obilježja emocionalne inteligencije. Konekcionistički modeli kombiniraju složene emocije iz bazičnih tipova poput, primjerice, straha, ljutnje ili veselja. Njihov intenzitet u određenom vremenu ovisi o pobudnim ili inhibitornim utjecajima drugih emotivnih tipova i elicitora neurološke, senzornomotorne, motivacijske i kognitivne vrste. Postavlja se pitanje zašto bi agenti trebali biti opremljeni barem fragmentima emocija. Razlog je što u nejasnim situacijama nepotpune informacije ljudi brzo povjeruju više svojim emocijama i intuitivnim iskustvima negoli analitičkom razmišljanju za koje treba vremena. Očito je da su konekcionistički modeli samo bihevioralni. No, u načelu, oni bi se, da bi se prizvelo osjećaje, mogli utjeloviti u neurokemijske mozgove i tijela.

Ljudska bića nisu nikakvi virtualni agenti. Mi smo utjelovljena bića, utjelovljeni u fizičkom okolišu, ekološkim i socijalnim nišama. Volimo se kretati i tjelesno interaktivno djelovati. Naše tijelo uvelike utječe na naš mozak. Istjelovljeni mozak jest kartezijanska iluzija. Moć kompjutera, stoga, ne bi se trebala koncentrirati na nekoliko superkompjutora kako bi stvorila svijet protivan našem fizičkom svijetu. Volimo djelovati u svojem prirodnom svijetu s bliskim stvarima svakodnevnoga života, no potpomognuti prednostima komputacijskih funkcija. Ukratko: komputacijska snaga trebala bi biti razdijeljena među stvari dnevne uporabe. Stvari stoga ne bi trebalo virtualizirati u virtualnoj stvarnosti, nego bi virtualnost trebala biti utjelovljena u stvarima ljudskoga života. To je filozofija posvudašnjeg računalstva.

U stoljeću koje započinje, globalna umreženost ne znači samo sve veći broj PC-ja, radnih stanica, servera i superkompjutora, koji međusobno djeluju preko prometa podacima na Internetu. Ispod složenosti PC-ja, u inteligentnom okolišu našega svakodnevnog života raspodjeljuju se jeftine i otmjene naprave niske snage. Primjeri poput tabova (tabs), padova (pads) i ploča: strojevi inčne razine koji se približavaju aktivnim post-iz zabilježkama (notes), zatim oni na razini stope (foot), koji se ponašaju kao list papira, knjiga ili časopis, te displeji na razini yarda, koji su ekvivalent ploči ili biltenu. Tabovi, padovi i ploče tek su početak posvudašnjeg računalstva. Pametne naprave jesu inteligentni mikroprocesori utjelovljeni u budilici, mikrovalnoj pećnici, TV daljinskom upravljaču, stereo i TV sustavima, dječjim igračkama, itd. Posvudašnje računalstvo čini da »stvari misle«, ne samo visoko inteligentni kompjutori nego i inteligentan organizam s inteligencijom jata. Sredstva bežične generacije treće generacije (3G) uključuju paketne mreže te međupovezanost kompjutoriziranih priključaka, poput telefona, faksova, printera, softverskog radija, itd. Tehnologije u razvoju traže brže konvertere podataka, jače procesore, Java i druge oblike download-nog softvera. Tehnički razvoj komunikatora-3G jest interdisciplinarna zadaća sustavnog inžinjerina.

Poput GPS (Global Position System) u automobilskom prometu, stvari svakodnevnog života mogu interaktivno djelovati telematski pomoću više ili manje inteligentnih senzora. Vozača auta koji koristi GPS telematski vodi mreža susjednih GPS stanica. U budućnosti, procesori, čipovi i displeji ovih pametnih naprava neće trebati korisničko sučelje poput miša, windowa ili ploče, nego tek prijatno i učinkovito mjesto gdje će se stvari događati. Sred-

stva bežičnog računalstva svih skala postaju sve nevidljivijima korisniku. Posvudašnje računalstvo omogućuje ljudima da žive, rade, koriste i uživaju u stvarima, a da nisu svjesni svojih računalnih naprava.

S tehničke točke gledišta, posvudašnje računalstvo izazov je za globalnu umreženost pomoću bežičnog medijskog pristupa, širokog pojasnog opsega, mogućnosti stvarnog vremena za multimedije iznad standardnih mreža, te rutine paketa podataka. Preko Interneta interaktivno djeluju ne samo milijuni PC-ja nego i bilijuni pametnih naprava. Oni su realne fizičke stvari različite skale, ali s virtualnim sjenkama podataka na Internetu koji traži moćnu složenost prometa podataka. Sveobuhvatni tok podataka i obavijesti sili nas da djelujemo na granici kaosa.

U 21. stoljeću informacije, komunikacije i biotehnologija će rasti zajedno. Proces obrade informacija stoga zahtijeva učenje iz prirode. Informacija se može stvarati, prenositi, pohranjivati, procesuirati i predstavljati u prirodi pomoću osjetilnih organa, živčanog sustava, mozga, spoznajnih procesa poput učenja i mišljenja, jezika, motorike, opažanja i komunikacije, koji se simuliraju u tehnologiji pomoću fizikalnih, kemijskih i bioloških senzora, kratkovalnih konduktora, elektronike, optičkih uređaja, mikroprocesora, nervnih mreža, robotike, virtualne stvarnosti, posvudašnjeg računalstva, umjetnog života i inteligencije, koji svi ciljaju na učeće, adaptirajuće i samorganizirajuće evolucijske složene sustave.

Razmatrali smo dinamiku prirodnih sustava (npr. atomske, molekularne, genetičke i neuronske sustave); komputacijske sustave (npr. kvantne, molekularne, DNA-, bio-, neuroračunalne sustave); globalnu umreženost (npr. Internet, rutinu, nalaženje informacija, multiagentne sustave); te posvudašnje računalstvo (npr. mobitele, GPS, PDA, pametne naprave, inteligentne okoliše). Globalna umreženost nije više izazov samo tehničkom razvoju. Posvudašnje računalstvo moglo bi poboljšati ljudsko sučeljavanje s informacijskim sustavima, no ne bi smjelo zbunjivati ljude mnoštvom tehničke opreme. Globalna umreženost mora se razviti kao tiha i nevidljiva tehnologija. Tiho i nevidljivo računalstvo nastoji integrirati globalnu umreženost i proces obrade informacija u ljudski okoliš i dnevni život, a da ljudi ne robuju tehničkim scenarijima. Globalna umreženost mora se razviti kao tehnički servis čovječanstva, ni više niti manje. Stoga proces obrade informacija u globalnim mrežama ne mogu gurati samo tehničke znanosti. To mora biti interdisciplinarna zadaća mikroelektronike, računalne i informacijske znanosti, ali i izazov kognitivnoj znanosti, sociologiji i općenito društvenim znanostima.

S antropološkog gledišta, posvudašnje računalstvo označava raspodjelu komputacijskih funkcija u infrastrukturi našega dnevnog života. Sučeljavanje korisnika s pojedinim kompjutorom koji simulira sve vrste predmeta, događaja i djelovanja u virtualnoj stvarnosti, zamjenjuje se familijarnom infrastrukturom realnih stvari za dnevnu uporabu, koje su opremljene skrivenim komputacijskim funkcijama. Interakcije su uglavnom bežične. S filozofske točke gledišta, klasično sučeljavanje korisnika i kompjutora odgovara dualizmu subjekta i objekta u Kantovoj epistemologiji, ili Descartesove i Husserlove distinkcije između svijesti i izvanjskoga svijeta. Prema Martinu Heideggeru, tradicionalna opreka subjekta i objekta mora se prevladati radi razumijevanja zdravoga razuma. Naša bliskost u situacijama dnevnoga života ne sastoji se u formalnim reprezentacijama pravila i činjenica, nego radije od sklonosti da se situacijama odgovori na prikladan način. Infrastrukturu je

Heidegger nazvao »bitkom-u-svijetu«, koji bi trebao nadomjestiti tradicionalan odnos subjekta i objekta, svijesti i izvanjskoga svijeta. Računalna tehnologija, dakle, mora biti utjelovljena u ljudskom »tubitku«, i to da bi poduprla naš *bitak-u-svijetu*. Naš je um utjelovljen u infrastrukturi našega dnevnoga života, a ne uhvaćen u izoliranom kavezu našega mozga.

4. Filozofija onkraj kognitivizma

Što su filozofske perspektive onkraj klasičnoga kognitivizma subjekta i objekta, svijesti i izvanjskoga svijeta, korisnika i kompjutora? To *onkraj* klasičnog kognitivizma ne znači nikakvo ograničenje za mentalne reprezentacije i posebne vrste prirodne inteligencije u smislu nekog IQ-testa, nego analiziranje svih vrsta i složenih stupnjeva samo-organizirajuće, pre-racionalne i racionalne, senzornomotorne i emocionalne spoznaje koje su se razvile u evoluciji. Ukratko: to onkraj klasičnoga kognitivizma označava utjelovljenu spoznaju. Na isti način, to onkraj klasične umjetne inteligencije ne znači nikakvo ograničenje za formalne reprezentacije i posebne vrste umjetne inteligencije u smislu Turingova testa, nego izgradnju svih vrsta i složenih stupnjeva samo-organizirajućih komputacijskih sustava kao servisnih sustava ljudskoga života: tako, to onkraj klasične AI označava novu umjetnu inteligenciju utjelovljene spoznaje.

Korištenje zakona složenih samo-organizirajućih sustava ne znači tek simulaciju postojećih organizama u prirodi nego iznalaženje inovacija u ljudske svrhe. U povijesti tehnologije čovječanstvo je naučilo letjeti ne simulirajući let ptice, nego iznašašćem zrakoplova. To su nova rješenja zakona aerodinamike koji nisu bili otkriveni pomoću prirodne evolucije. Drugi su primjer zakoni neuronskih mreža. Mozgovi i živčani sustavi su tek neka rijetka rješenja što ih je pronašla prirodna evolucija. Čip-tehnologija pruža nove uspješne inovacije s ponekad različitim postupcima. Trebali bismo tražiti tehničke solucije samo-organizirajućih sustava kao servisnih sustava ljudske vrste. Treba nam, dakle, interdisciplinarni pristup ljudski usredotočene tehnologije uz sudjelovanje robotike, računalne znanosti, umjetne inteligencije, znanosti života, te društvenih znanosti.

Mnogi problemi stare i nove kognitivne znanosti, stare i nove umjetne inteligencije, robotike, istraživanja mozga, itd. očito imaju duboke filozofske korijene u klasičnoj i analitičkoj filozofiji. Osim toga, koncepcija utjelovljenog uma prilično je popularna – ne samo u filozofiji! Tjelesnost, zdravlje i blagostanje temeljne su teme javnog interesa. Zdravlje je glavni problem javnoga budžeta. Znanost života postala je vodećom znanošću 21. stoljeća (nakon fizike u 20. stoljeću). Ekonomisti tvrde da će za petim Kondratieffskim krugom informacijskog društva slijediti šesti Kondratieffski krug zdravlja i industrije. U biti, u teoriji evolucije, život, informacija i računalna znanost rastu zajedno. S filozofske točke gledišta, moje koncepcije tehnike i tjelesnosti imaju dugu tradiciju. U izvornom (grčkom) značenju, tehnika je svrhovito sredstvo kao ljudski servis. Naše tijelo nije nikakav kartezijanski stroj ili platoniska tamnica duše. U aristotelovskoj tradiciji utjelovljenje označava čitav organizam s njegovom utjelovljenom entelehijom i intencionalnošću. Ono je naš individualni izvor života, kreativnosti i blagostanja. Trebali bismo se pobrinuti za njega.

Literatura:

- Dewey, John (1981), »The reflex arc in psychology«, *Psychological Review* 3, 1986, 357–370. Preštampano u: John J. McDermott (ur.), *The Philosophy of John Dewey*. Chicago: University of Chicago Press, 136–148.
- Dreyfus, Hubert L. (1991), *Being-in-the-World: A Commentary on Heidegger's »Being and Time«*. Cambridge, MA: MIT Press.
- Dreyfus, Hubert L. (1979), *What Computer's Can't Do. The Limits of Artificial Intelligence*. New York: Harper & Row.
- Dreyfus, Hubert L. (1982), *Husserl, Intentionality, and Cognitive Science*. Cambridge, MA: MIT Press.
- Fetzer, James H. (ur., 1988), *Aspects of Artificial Intelligence*. Dordrecht: Kluwer Academic Publishers.
- Floridi, Luciano (ur., 2003), *Philosophy of Computing and Information*. Oxford: Blackwell.
- Mainzer, Klaus (2003), *Thinking in Complexity. The Computational Dynamics of Matter, Mind, and Mankind*, 4. prošireno izdanje. New York: Springer.
- Mainzer, Klaus (2003), *KI – Künstliche Intelligenz. Grundlagen intelligenter Systeme*. Darmstadt: Wissenschaftliche Buchgesellschaft.
- Mainzer, Klaus (2003), *Computerphilosophie – Zur Einführung*. Hamburg: Junius Verlag.
- Mainzer, Klaus (1999), *Computernetze und virtuelle Realität. Leben in der Wissensgesellschaft*. Heidelberg: Springer.
- Mainzer, Klaus (1997), *Gehirn, Computer, Komplexität*. Heidelberg: Springer.
- Merleau-Ponty, Maurice (1962), *Phenomenology of Perception*. London: Routledge & Kegan Paul.
- Pfeifer, Rolf / Scheier, Christian (2001), *Understanding Intelligence*. Cambridge, MA: MIT Press.
- Putnam, Hilary (1981), *Reason, Truth, and History*. Cambridge, MA: MIT Press.
- Schank, Roger C. / Childers, Peter G. (1986), *Die Zukunft der Künstlichen Intelligenz. Chancen und Risiken*. Köln.
- Searle, John R. (1969), *Speech Acts*. Cambridge, MA: MIT Press.

Klaus Mainzer

The Embodied Mind

Modern cognitive science cannot be understood without recent developments in computer science, Artificial Intelligence (AI), robotics, neuroscience, biology, linguistics, and psychology. Classic analytic philosophy as well as traditional AI assumed that all kinds of knowledge must explicitly be represented by formal or programming languages. This assumption is in contradiction to recent insights into the biology of evolution and developmental psychology of the human organism. Most of our knowledge is implicit and unconscious. It is not formally represented, but embodied knowledge which is learnt by doing and understood by bodily interacting with ecological niches and social environments. That is true not only for low-level skills, but even for high-level domains of categorization, language, and abstract thinking. Embodied cognitive science, AI, and robotics try to build the embodied mind in an artificial evolution. From a philosophical point of view, it is amazing that the new ideas of embodied mind and robotics have deep roots in the history of philosophy.

Key words

cognitive science, artificial intelligence (AI), embodied mind, computer science, robotics, neuroscience, linguistics, psychology