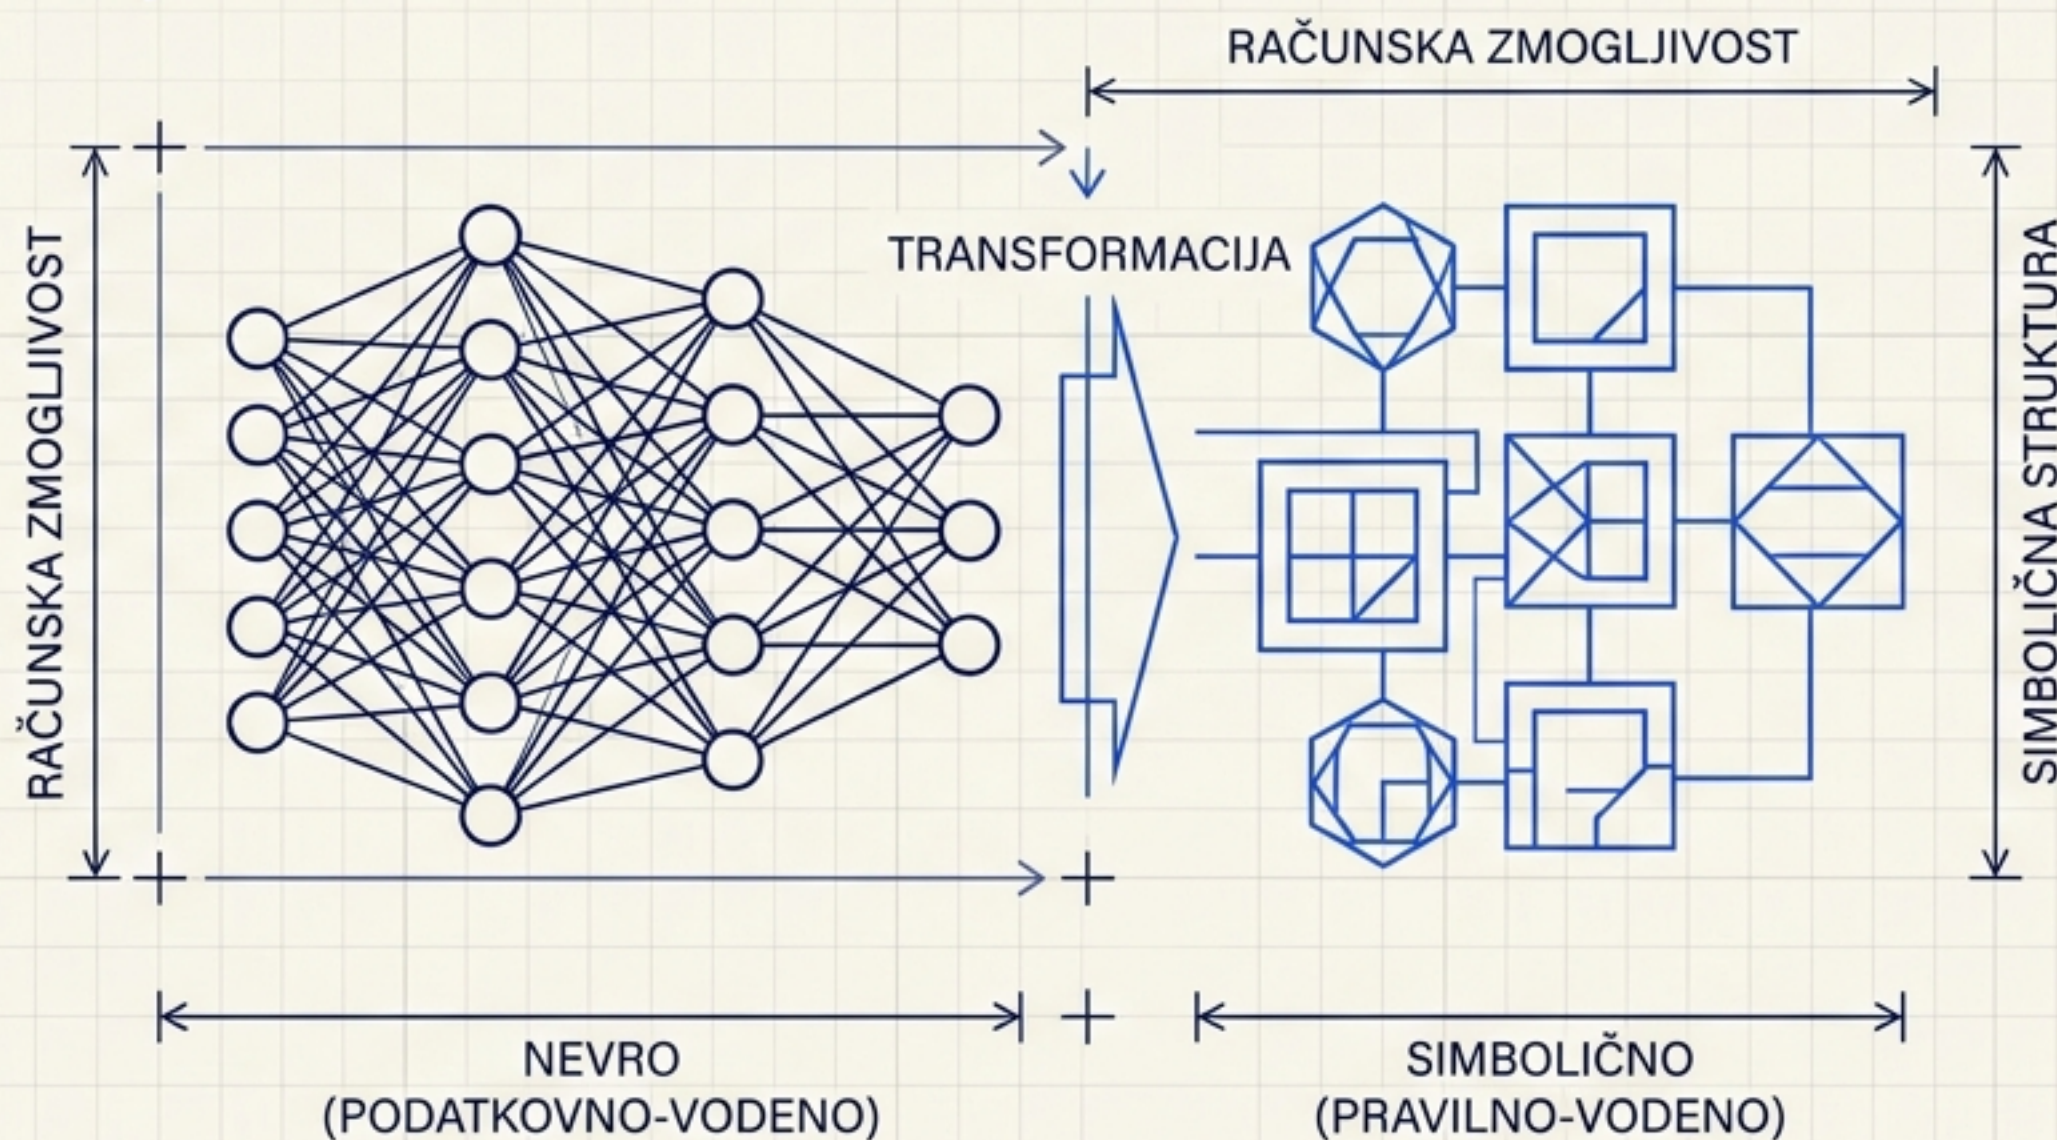


Nova paradigma v robotiki: Nevro-simbolična umetna inteligenca

Arhitekturna rešitev za energetska in računsko učinkovitost
vizualno-jezikovno-akcijskih (VLA) modelov



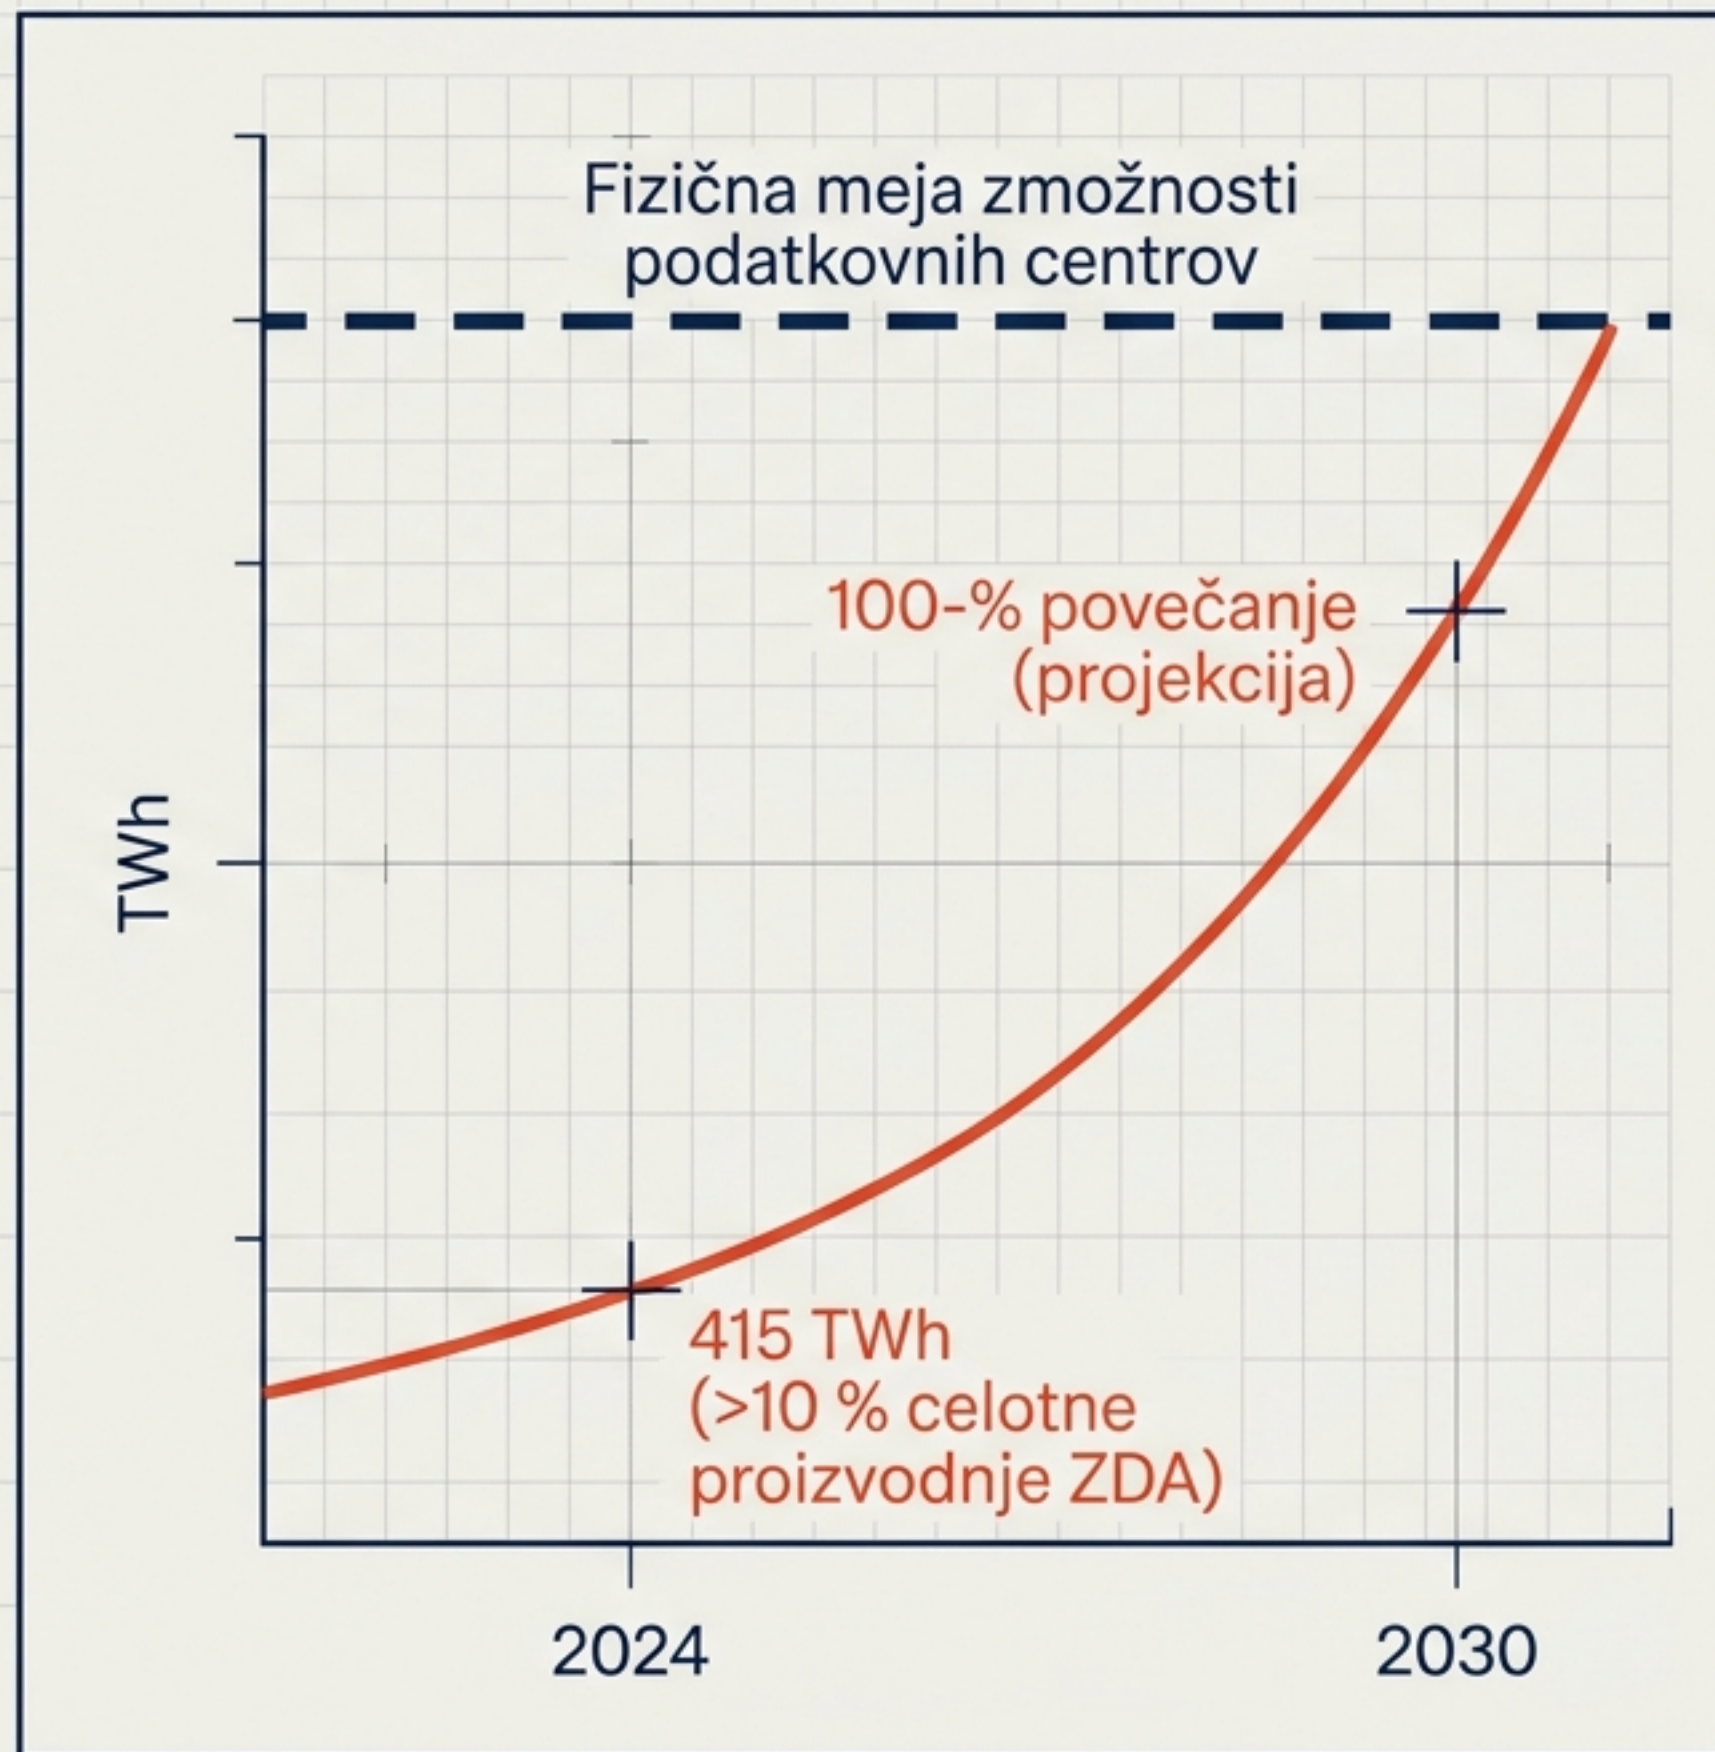
Raziskovalna sinteza:
Matthias Scheutz Lab, Tufts University

EkspONENTNO SKALIRANJE TRČI OB ENERGETSKI ZID

Anomalija učinkovitosti:

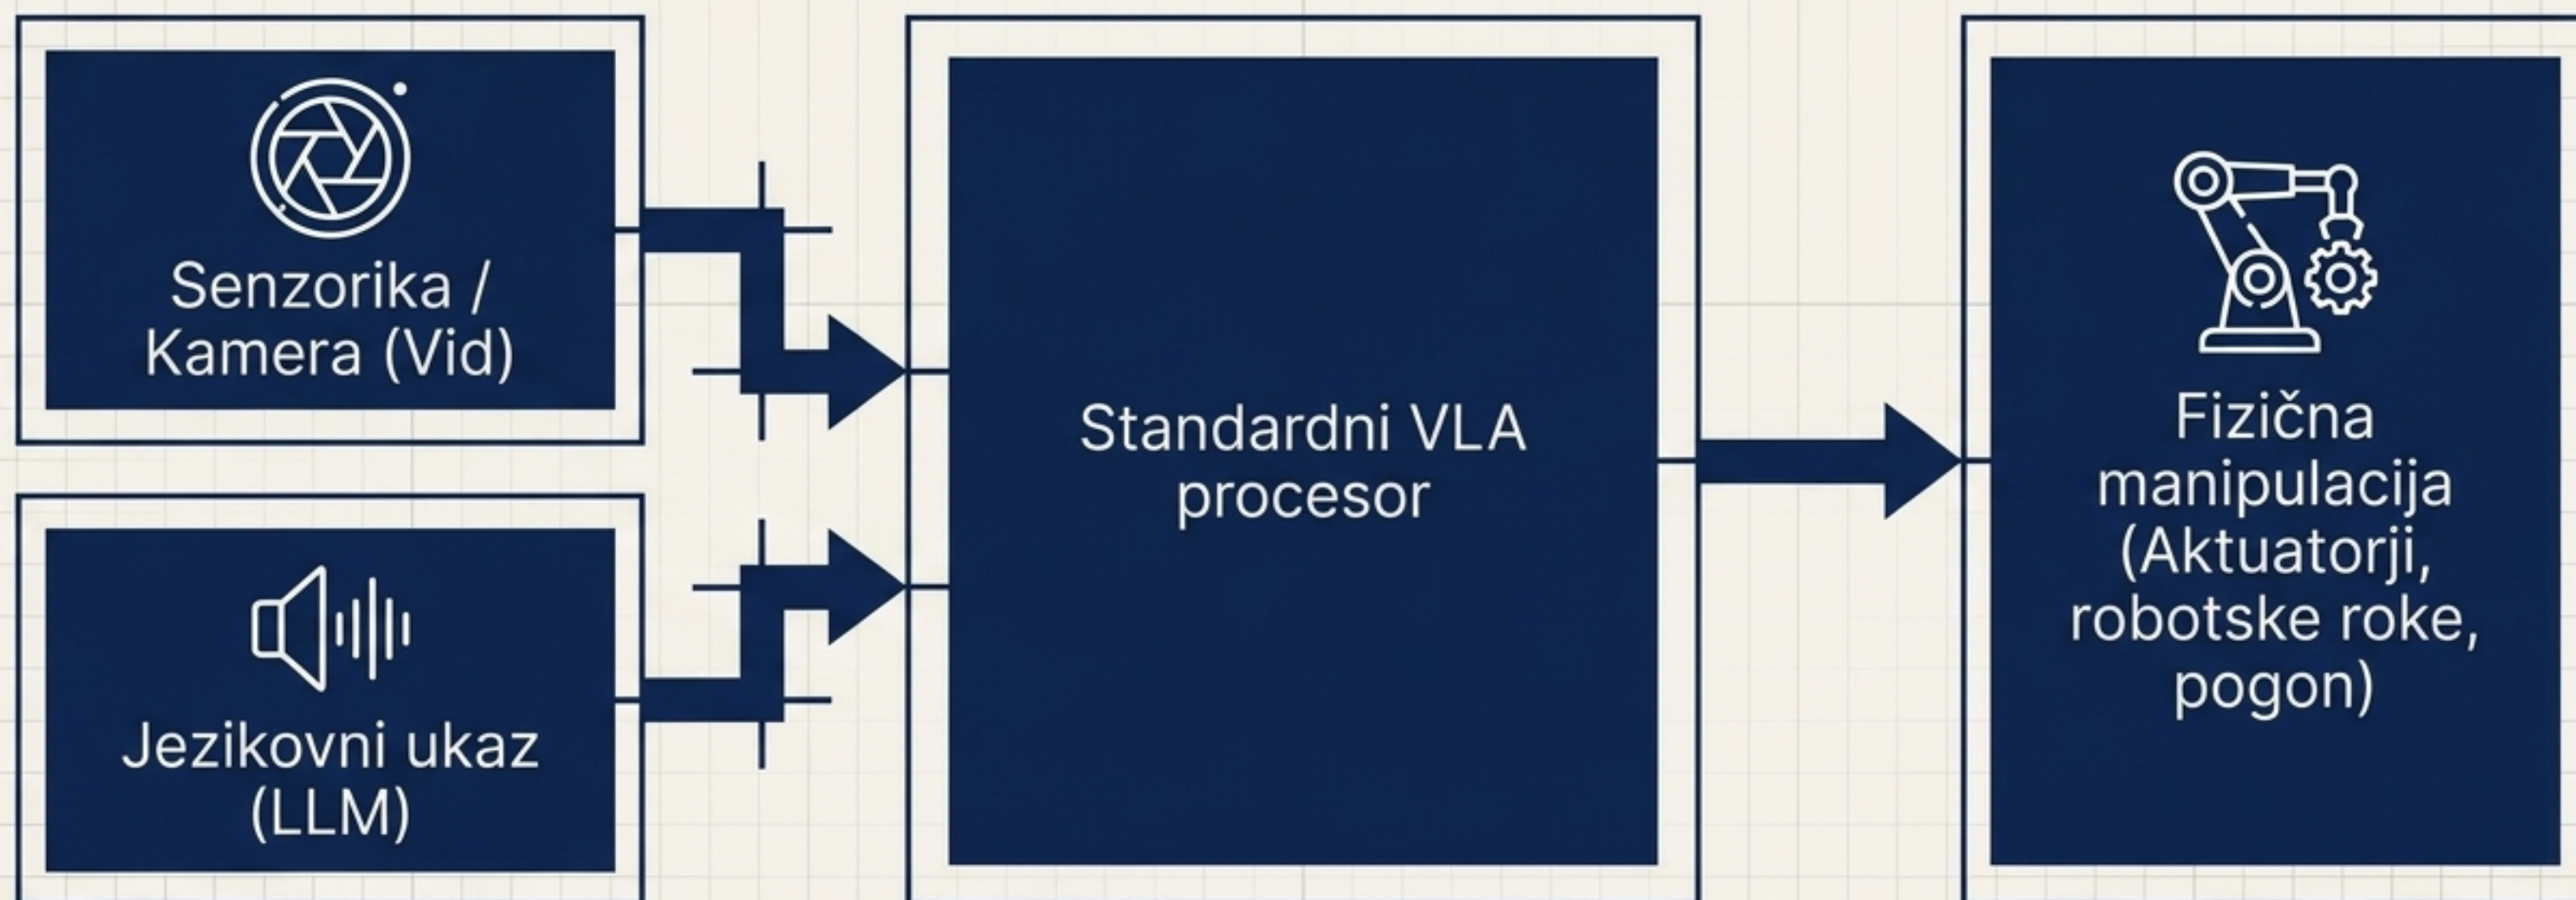
Generiranje UI povzetka pri Google iskanju porabi do 100-krat več energije kot zgolj izpis seznama iskalnih zadetkov.

Energetski vložek tradicionalnih modelov je disproporcionalen preprostim nalogam.




Vizualno-jezikovno-akcijski (VLA) modeli

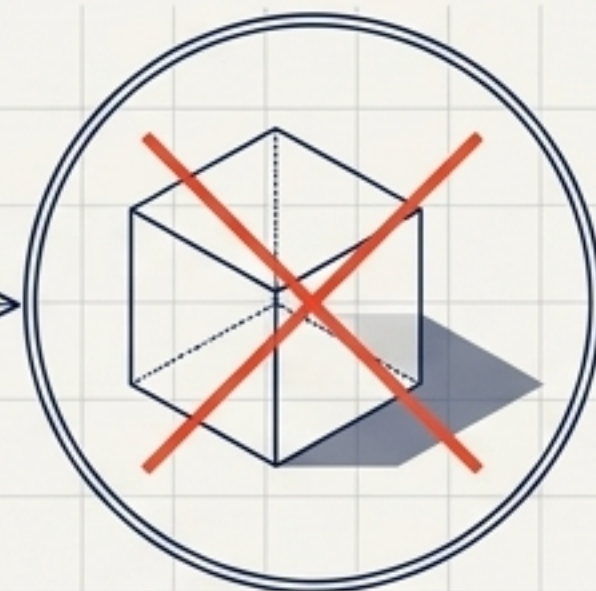
LLM arhitektura, razširjena za generiranje fizičnih akcij v realnem okolju.



Ozko grlo statističnega učenja: Fizične halucinacije




[A] Vizualna napaka



Napačna interpretacija:
Model zamenja vizualno
senco za fizični rob objekta.

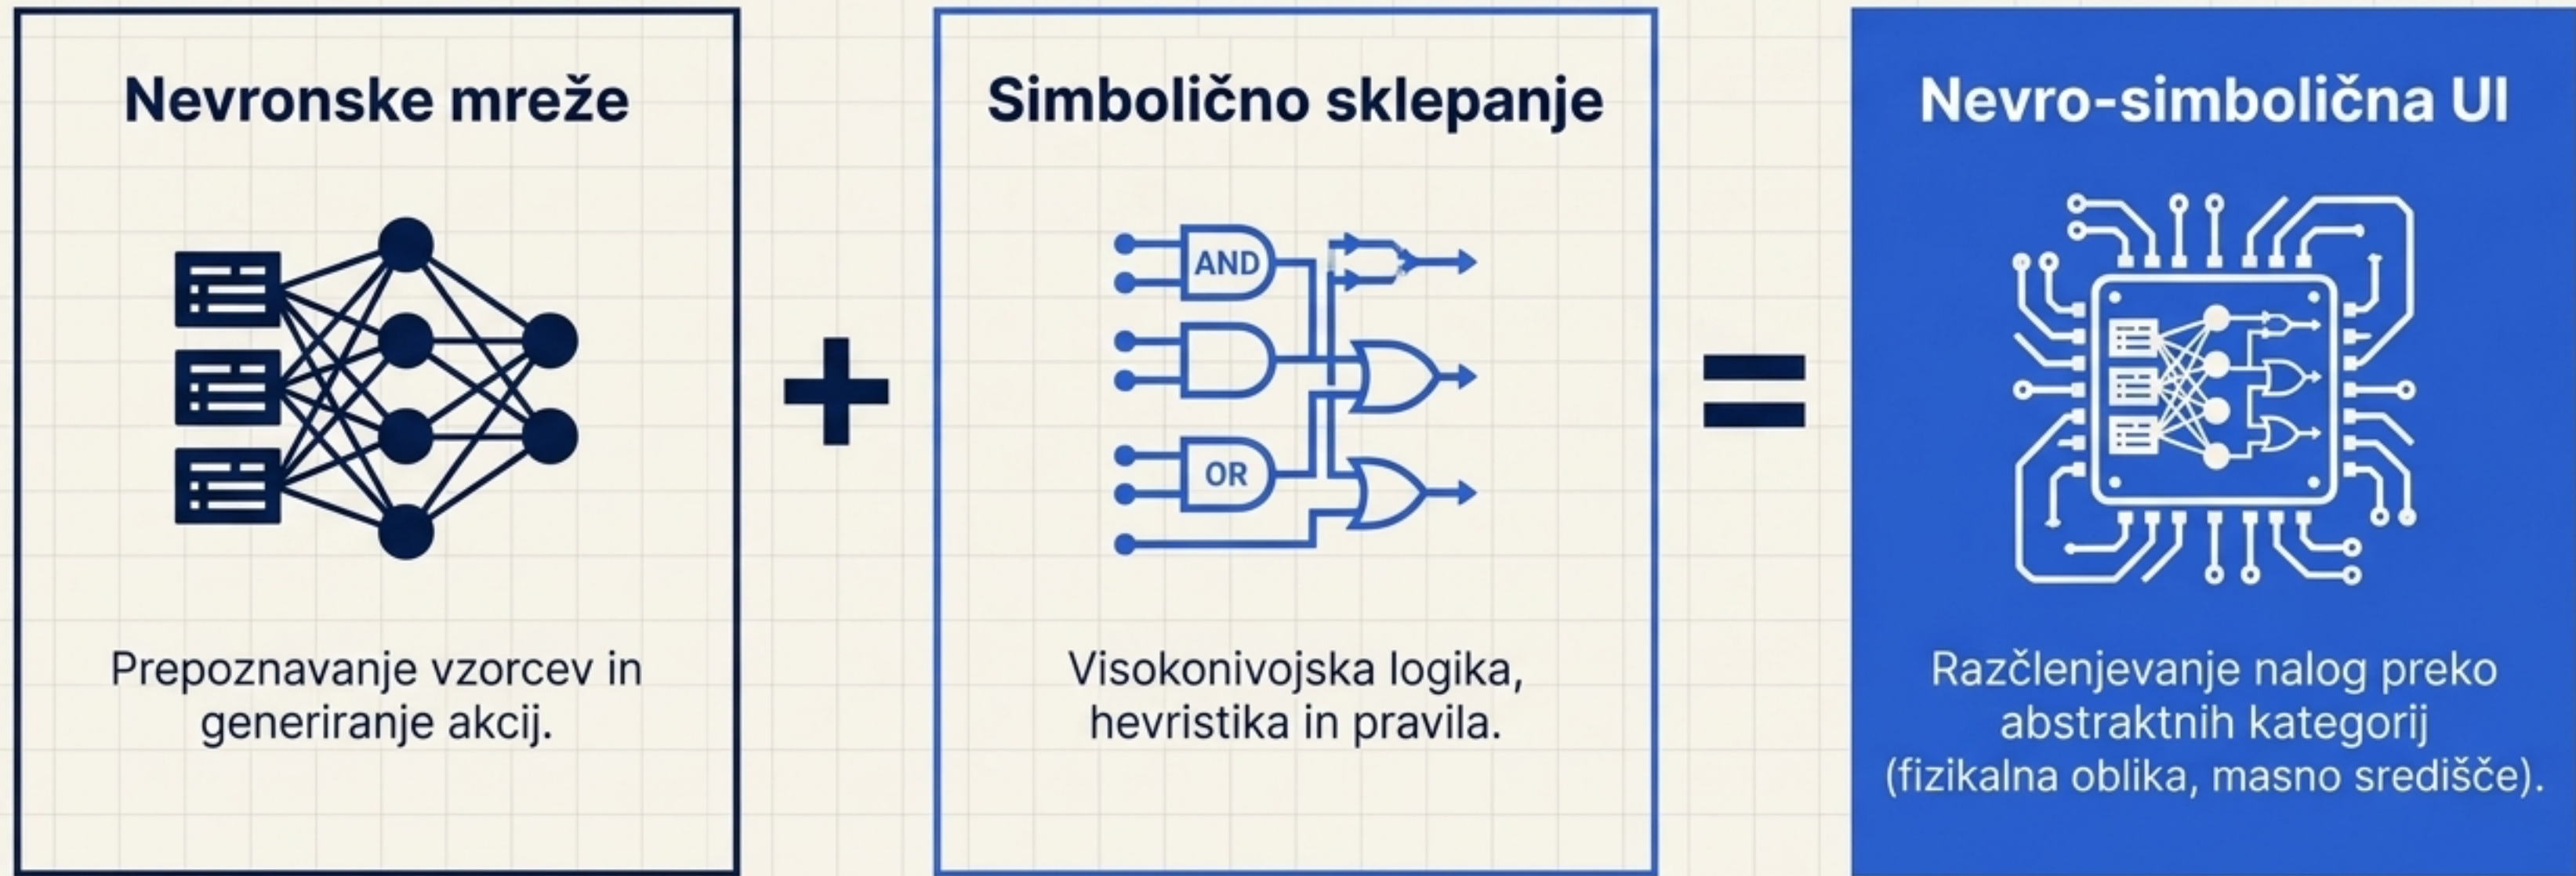
[B] Mehanska napaka



Napačna postavitev:
Napačna ocena masnega
središča, ki povzroči
prevračanje stolpa.


Omejitev: Standardni modeli delujejo izključno na podlagi statističnih korelacij iz učnih množic, brez razumevanja fizikalnih zakonov. Sistem se zanaša na neučinkovito metodo poskusov in napak (trial-and-error).

Hibridna arhitektura: Neuro-simbolični VLA (NS-VLA)



Mehanika: Optimizacija iskalnega prostora s fiziko

Standardni VLA: Eksponentni iskalni prostor





Nevro-simbolični VLA: Deduktivni rez




Sistem ne zavrzuje računskih virov za preverjanje iteracij, ki vnaprej kršijo osnove fizike ali geometrije.

Arhitekturna primerjalna matrika

	Standardni VLA 	Nevro-simbolični VLA 
Mehanizem učenja	Statistične korelacije na masovnih učnih množicah.	Nevronske mreže, kombinirane z vgrajeno arhitekturno hevrstiko.
Metoda korekcije napak	Izključno zanašanje na povratne zanke (trial-and-error).	Deduktivno omejevanje iskanja preko vnaprejšnjih fizikalnih pravil.
Prostorsko razumevanje	Zanašanje na verjetnostno razporeditev pikslov.	Razumevanje in uporaba abstraktnih kategorij (oblika, težišče, dimenzije).

Empirična validacija: Eksperiment Hanojskega stolpa



Scenarij 1: Standardna naloga

Okolje in postavitev diskov sta modelu v celoti znana iz pretekle faze strojnega učenja.


Testiranje hitrosti in natančnosti.

Scenarij 2: Kompleksna različica

Novi, spremenjeni pogoji in razporeditev v prostoru, ki jih model še nikoli ni videl. Rigorozen preizkus sposobnosti posploševanja (**Zero-shot generalization**).

Telemetrija uspešnosti in sposobnost posploševanja


Standardna naloga (znano okolje)



Kompleksna, še nevidena naloga (Zero-shot)




Časovna kompleksnost: EkspONENTNO hitrejši trening

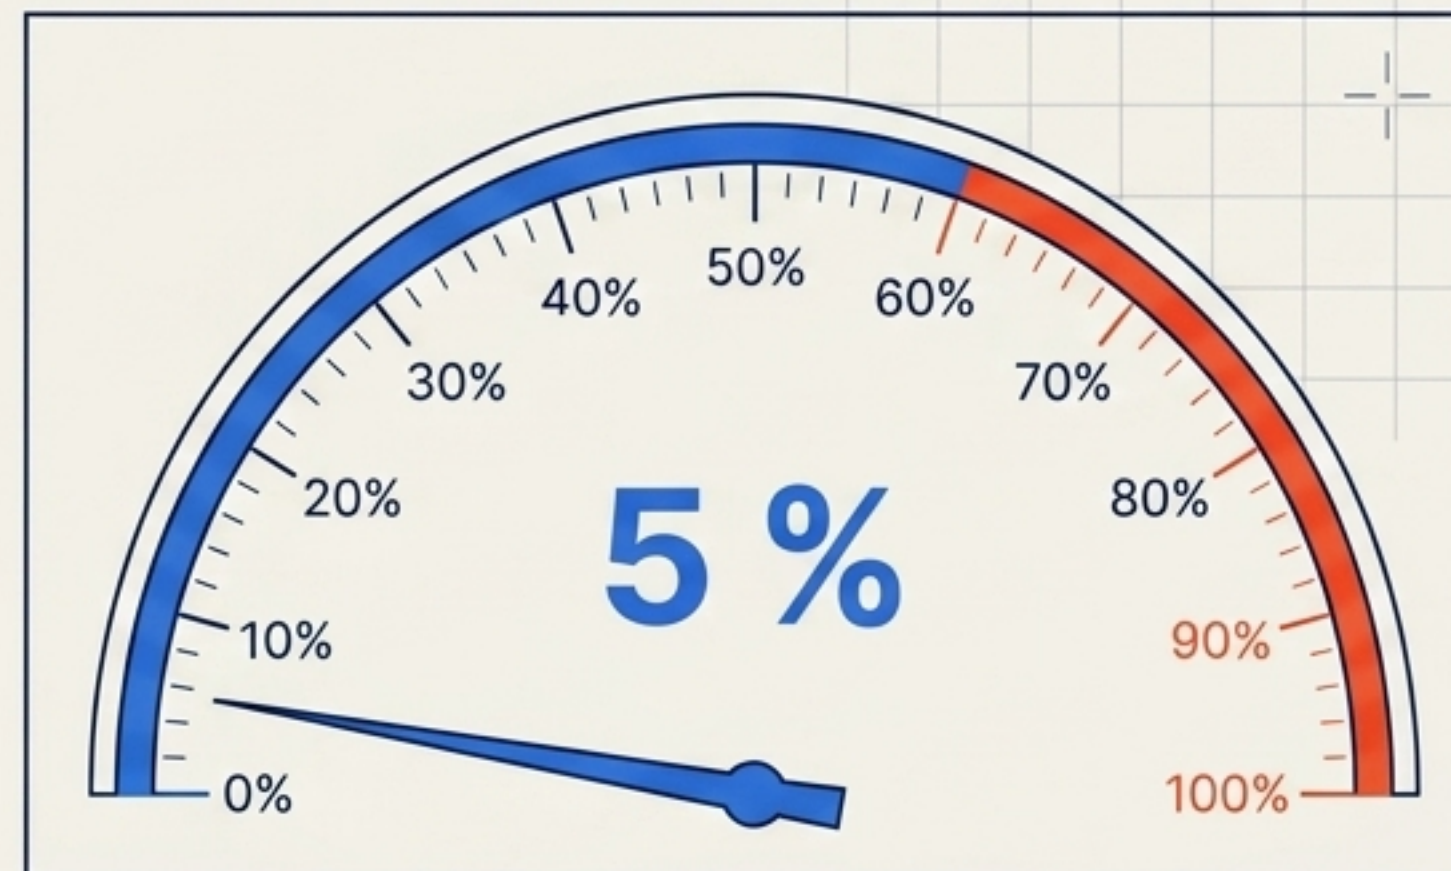


Izjemno **zmanjšanje** potrebe po iteracijah poskusov in napak med **fazo učenja** omogoča skoraj **takojšnjo uporabnost** modela.

Odprava energetskega zidu: Radikalno zmanjšanje porabe




Poraba energije za trening modela
(v primerjavi s standardnim VLA)




Poraba energije pri izvajanju
(Inference & izvedba akcij)

Sinteza: Od surove moči do pametne arhitekture

Surova moč / Brute-Force Data Center



Pametna Arhitektura / Smart Architecture



Skaliranje podatkov in dodajanje strojne opreme (brute-force pristop) ni dolgoročno trajnostna osnova za zanesljivo umetno inteligenco.

Elegantna logika na nivoju programske arhitekture (vgrajena fizikalna pravila) je absolutno superiorna surovemu dodajanju računske moči.

Prihodnost UI v robotiki so hibridni sistemi: operativno trajnostni z minimalno porabo energije in deterministično zanesljivi v fizičnem svetu.