



LARANA, INC.

UMJETNA INTELIGENCIJA I HALUCINACIJE PRI UPORABI U.I.

HANA BRKIĆ 3.A

ZAŠTO UMJETNA INTELIGENCIJA "HALUCINIRA" PODATKE

ZNANSTVENIK DOUGLAS HOFSTADTER, U SVOJOJ JE DEMONSTRACIJI PRIJE DVije GODINE, POKAZAO KAKO LAKO AI MOŽE "HALUCINIRATI" INFORMACIJE.

HALUCINACIJE, IAKO PROBLEMATIČNE, OTKRIVAJU KLJUČNU RAZLIKU U KORIŠTENJU UMJETNE INTELIGENCIJE: KAO GENERATORA SADRŽAJA U ODНОСУ NA IZVOR INFORMACIJA.

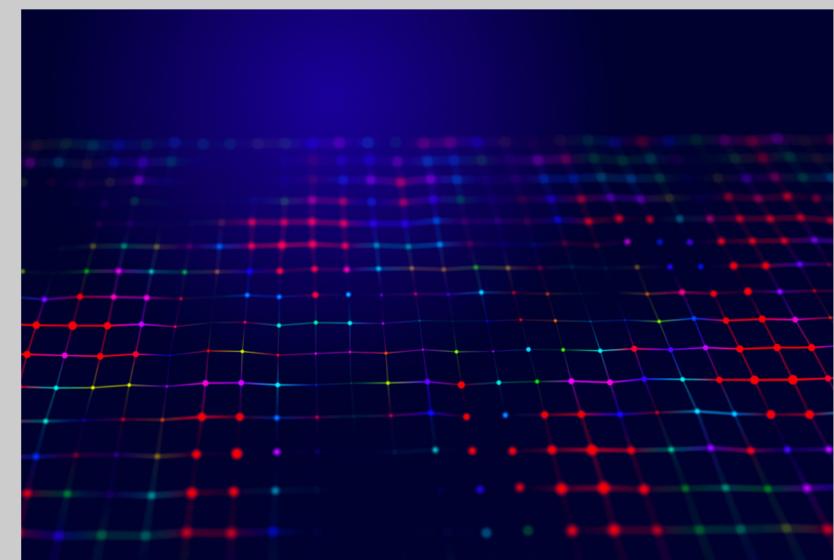
KAKO AI PONEKAD STVARA NETOČNE INFORMACIJE?



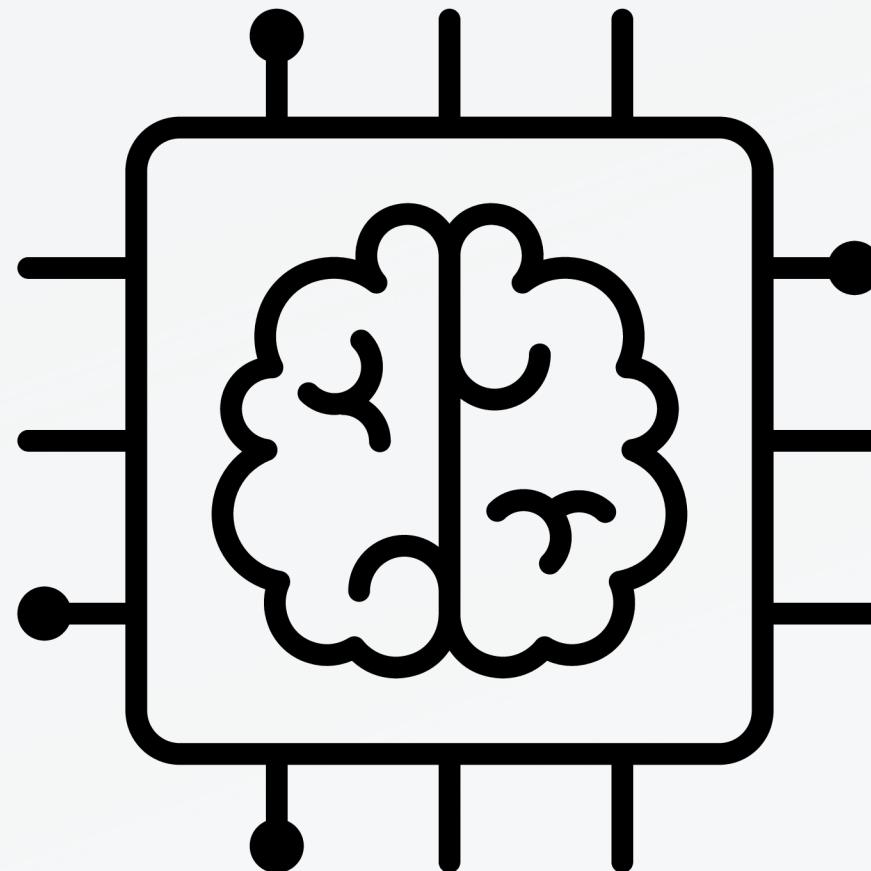
Korijen leži u njegovoj obuci. Generativni AI modeli, izgrađeni na golemim skupovima podataka koji obuhvaćaju različite izvore, izvrsni su u oponašanju jezika koji su usvojili.



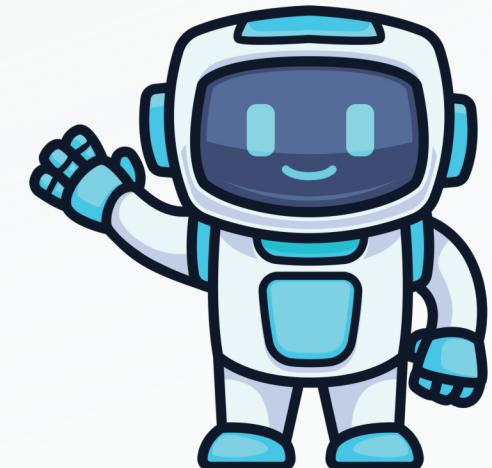
Halucinacije, odnosno odstupanja od stvarnosti, mogu proizaći iz neadekvatne obuke ili pristranih podataka, ostavljajući model neopremljenim za određene upite korisnika.

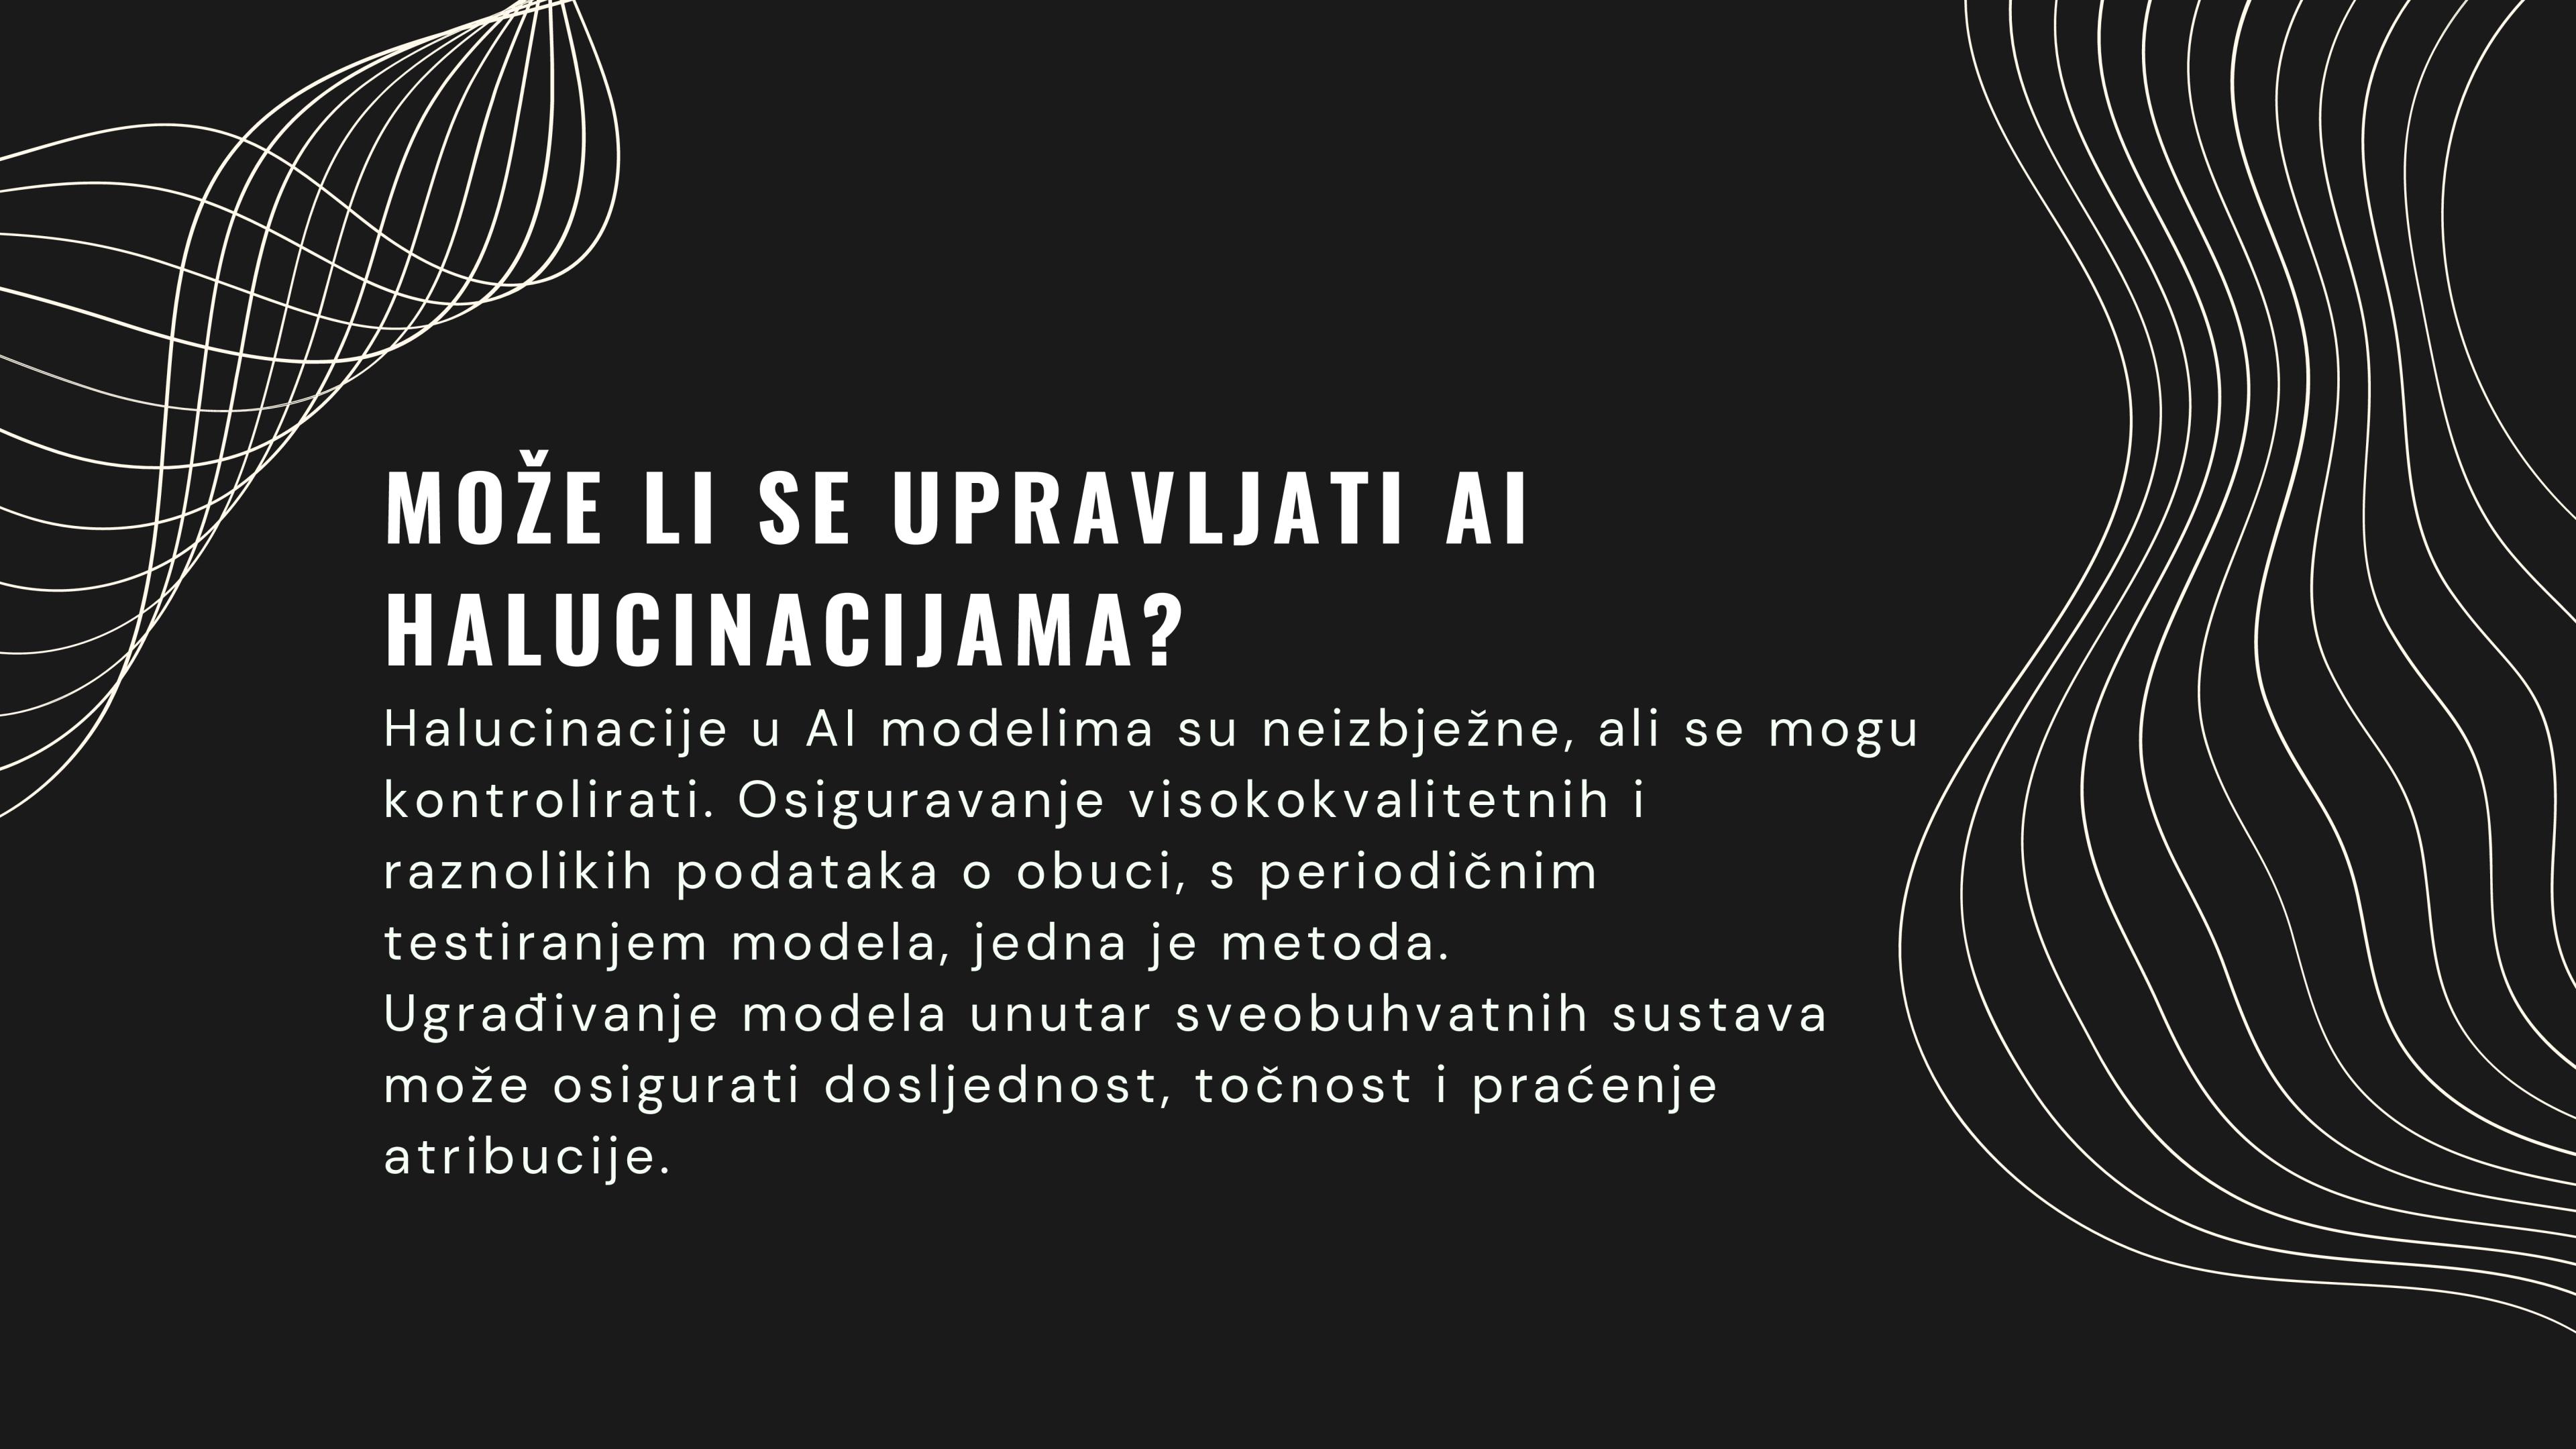


KOLIKO ČESTO UMJETNA INTELIGENCIJA HALUCINIRA?



- Google naglašava stalne napore za povećanje točnosti umjetne inteligencije, priznajući da su pogreške ili halucinacije i dalje izazov. Microsoft izvještava o napretku u ublažavanju izmišljotina usavršavanjem tehnika uzemljenja, finog podešavanja i upravljanja u svojim AI modelima i chatbotovima.





MOŽE LI SE UPRAVLJATI AI HALUCINACIJAMA?

Halucinacije u AI modelima su neizbjegne, ali se mogu kontrolirati. Osiguravanje visokokvalitetnih i raznolikih podataka o obuci, s periodičnim testiranjem modela, jedna je metoda.

Ugrađivanje modela unutar sveobuhvatnih sustava može osigurati dosljednost, točnost i praćenje atribucije.

HOĆE LI PROBLEM AI HALUCINACIJA IKADA BITI RIJEŠEN?

- Halucinacije, proizašle iz ograničenja podataka i neadekvatnog poznavanja svijeta, predstavljaju značajne izazove. Cilj istraživača je riješiti ih kroz poboljšane podatke o obuci, rafinirane algoritme i integraciju mehanizama za provjeru činjenica.
- Tehnološke tvrtke sada uključuju odricanje od odgovornosti u vezi s halucinacijama, ali ljudski nadzor i vladini propisi ostaju ključni.

**HVALA NA
POZORNOSTI!**

.S.

