

---

Marko Kimi Milić<sup>1</sup>, Šćepan Sinanović<sup>1</sup>, Tanja Prodović<sup>1</sup>,  
Tanja Ilanković<sup>1</sup>

## VEŠTAČKA INTELIGENCIJA U DIJAGNOSTICI ENDOKRINIH POREMEĆAJA: FOKUS NA DIJABETES I BOLESTI ŠTITASTE ŽLEZDE

**Apstrakt:** Cilj ovog istraživanja je da se ispita primena veštačke inteligencije (VI) u dijagnostici endokrinih poremećaja, sa posebnim osvrtom na dijabetes i bolesti štitaste žlezde. Veštačka inteligencija, posebno algoritmi mašinskog učenja (ML) i dubokog učenja (DL), pokazala se kao ključna tehnologija u medicini, omogućavajući ranu dijagnozu i preciznu procenu složenih medicinskih stanja. Ovaj rad pruža pregled trenutnih tehnoloških rešenja, uključujući analizu tačnosti, osetljivosti i specifičnosti različitih AI algoritama, kao i njihovu efikasnost u poređenju sa tradicionalnim dijagnostičkim metodama.

Metodološki, rad se oslanja na sistematičan pregled dostupne literature i studija slučaja koje analiziraju upotrebu algoritama kao što su konvolucione neuronske mreže (CNN) i mašine sa podrškom vektora (SVM). Rezultati pokazuju da AI alati pružaju značajnu prednost u odnosu na klasične pristupe, s tačnošću od preko 90% u identifikaciji ključnih biomarkera i abnormalnosti u rezultatima laboratorijskih analiza. Posebno je istaknuta uloga algoritama u personalizaciji dijagnostičkih protokola i optimizaciji toka lečenja.

Zaključak istraživanja naglašava potencijal veštačke inteligencije da unapredi dijagnostiku endokrinih poremećaja i doprinese razvoju održivih, visokopreciznih rešenja u zdravstvenom sistemu. Istovremeno, ističu se izazovi, poput etičkih pitanja, integracije u kliničku praksu i neophodnosti standardizacije podataka. Buduća istraživanja trebalo bi da se fokusiraju na optimizaciju algoritama i njihovu primenu u realnim kliničkim okruženjima.

**Ključne reči:** veštačka inteligencija, endokrini poremećaji, dijabetes, bolesti štitaste žlezde, dijagnostika, algoritmi mašinskog učenja

---

<sup>1</sup> Marko Kimi Milić, Visoka medicinska škola strukovnih studija „Milutin Milanković”, Beograd, Srbija, e-mail: scep.ananovic@gmail.com

## UVOD

### Značaj endokrinih poremećaja

Endokrini poremećaji predstavljaju sve veći globalni izazov u javnom zdravlju, s obzirom na njihovu učestalost i dugotrajne posledice. Među najčešćim endokrinim oboljenjima su dijabetes, poremećaji rada štitaste žlezde, adrenalne insuficijencije i poremećaji hipofize. Dijabetes, kao jedno od najznačajnijih stanja u ovoj grupi, prema podacima Međunarodne federacije za dijabetes (IDF), pogađa preko 537 miliona odraslih osoba širom sveta, dok se očekuje da će ovaj broj dostići 643 miliona do 2030. godine [1, 2].

Ovi poremećaji imaju višestruke posledice, od metaboličkih komplikacija do kardiovaskularnih bolesti, koje predstavljaju vodeći uzrok smrti u populaciji osoba sa dijabetesom [3]. Osim toga, bolest štitaste žlezde, kao što je hipotireoidizam, može ostati nedijagnostikovana godinama zbog nespecifičnih simptoma, što povećava rizik od ozbiljnih komplikacija, uključujući neplodnost i neuropsihijatrijske poremećaje [4]. Efikasna i rana dijagnostika ovih stanja igra ključnu ulogu u prevenciji ozbiljnijih posledica, ali trenutni dijagnostički alati često nisu dovoljno brzi i pouzdani, čime se otvara prostor za primenu inovativnih tehnologija poput veštačke inteligencije [5].

### Veštačka inteligencija u medicini

Veštačka inteligencija (VI) se ubrzano razvija kao ključna tehnologija u modernoj medicini. VI obuhvata algoritme i sisteme koji omogućavaju računarima da analiziraju velike količine podataka, identifikuju obrasce i donose predikcije na osnovu kompleksnih informacija [6]. Među najvažnijim granama VI su mašinsko učenje (ML) i duboko učenje (DL), koje se sve češće koriste za rešavanje problema u medicinskim oblastima kao što su radiologija, onkologija i kardiologija [7]. Na primer, duboko učenje, posebno algoritmi konvolucionih neuronskih mreža (CNN), već se pokazalo kao izuzetno uspešno u analizi medicinskih slika, sa tačnošću koja nadmašuje tradicionalne metode u dijagnostici [8].

Primena VI u oblasti endokrinologije ima ogroman potencijal. Na osnovu analize laboratorijskih podataka, biomarkera i medicinskih slika, VI algoritmi mogu omogućiti precizniju i bržu dijagnostiku. Na primer, mašinsko učenje se koristi za procenu nivoa glukoze u krvi, analizu varijabilnosti šećera u krvi kod dijabetičara i predikciju komplikacija poput dijabetičke retinopatije [9]. U oblasti bolesti štitaste žlezde, algoritmi su uspešno korišćeni za identifikaciju abnormalnosti u ultrazvučnim snimcima i procenu rizika od malignih promena [10].

## Ciljevi istraživanja

Ovaj rad ima za cilj da istraži primenu veštačke inteligencije u dijagnostici endokrinih poremećaja i proceni njenu efikasnost u odnosu na konvencionalne metode. Ciljevi istraživanja uključuju:

- Analizu uloge algoritama veštačke inteligencije u ranoj dijagnostici i personalizaciji lečenja dijabetesa i poremećaja štitaste žlezde.
- Ispitivanje performansi različitih VI algoritama, uključujući preciznost, osetljivost i specifičnost.
- Identifikaciju ključnih izazova i ograničenja u integraciji veštačke inteligencije u kliničku praksu.

## Hipoteze

Na osnovu dostupnih podataka i prethodnih istraživanja, formulisane su sledeće hipoteze:

H1: Algoritmi veštačke inteligencije omogućavaju veću tačnost i pouzdanost u dijagnostici endokrinih poremećaja u poređenju sa tradicionalnim metodama.

H2: Integracija veštačke inteligencije u procese dijagnostike smanjuje vreme potrebno za donošenje dijagnoze.

H3: Korišćenje veštačke inteligencije doprinosi smanjenju grešaka u interpretaciji kliničkih podataka, što rezultira boljim ishodima lečenja.

## Pregled trenutnog stanja

Iako se VI sve češće primenjuje u raznim medicinskim disciplinama, u oblasti endokrinologije njen potencijal nije u potpunosti iskorišćen. Prethodna istraživanja pokazuju da algoritmi, poput CNN i SVM, pružaju obećavajuće rezultate u analizi medicinskih podataka. Na primer, istraživanje sprovedeno na uzorku pacijenata sa dijabetesom pokazalo je da VI algoritmi postižu tačnost od preko 90% u identifikaciji visokog rizika za komplikacije, što je značajno unapređenje u poređenju sa standardnim metodama [11].

Međutim, primena VI nosi određene izazove. Integracija u kliničku praksu zahteva visok kvalitet podataka, koji često nedostaje u medicinskim ustanovama. Takođe, nedostatak standardizacije u primeni algoritama i etička pitanja, poput privatnosti podataka, ostaju ključne prepreke [12].

## **Pregled strukture rada**

Kako bi se istražio navedeni problem, rad je podeljen u nekoliko ključnih poglavlja. U uvodnom delu opisuje se značaj problema i potencijal veštačke inteligencije u njegovom rešavanju. Metodološki deo pruža detaljan pregled analize sekundarnih podataka i korišćenih algoritama. Rezultati istraživanja prezentuju performanse različitih VI rešenja, dok diskusija analizira nalaze u kontekstu trenutne prakse, identifikujući prednosti i ograničenja. Na kraju, zaključak rezimira nalaze istraživanja i predlaže buduće pravce razvoja.

## **METOD**

### **Pristup istraživanju**

Ovo istraživanje zasnovano je na sistematičnom pregledu literature i sekundarnoj analizi podataka. Korišćeni su radovi koji se bave primenom algoritama veštačke inteligencije u dijagnostici endokrinih poremećaja, sa posebnim osvrtom na dijabetes i bolesti štitaste žlezde. Analiza je sprovedena u skladu sa PRISMA protokolom, kako bi se obezbedila standardizacija i transparentnost u selekciji i evaluaciji izvora [13].

### **Izvori podataka**

Podaci su prikupljeni pretragom naučnih baza poput PubMed, IEEE Xplore, Scopus i ScienceDirect. Ključne reči korišćene u pretrazi uključivale su “artificial intelligence”, “machine learning”, “deep learning”, “endocrine disorders”, “diabetes diagnostics” i “thyroid disease”. Pretraga je bila ograničena na radove objavljene od 2015. do 2023. godine, kako bi se obuhvatila najsavremenija dostignuća u oblasti veštačke inteligencije u medicini [14].

Kriterijumi za uključivanje su bili:

- Radovi koji se fokusiraju na primenu VI u dijagnostici endokrinih poremećaja.
- Studije koje sadrže kvantitativne rezultate, uključujući metrike poput tačnosti, specifičnosti i osetljivosti algoritama.
- Istraživanja objavljena u recenziranim časopisima ili zbornicima naučnih konferencija.

Iz pretrage su isključeni radovi koji ne obuhvataju direktnu primenu VI u medicinskoj praksi, kao i oni bez dostupnih kvantitativnih podataka.

## Selekcija i analiza podataka

Ukupno 164 rada je identifikovano u početnoj pretrazi, od kojih su 47 isključeni zbog dupliranja, dok su preostalih 117 prošli kroz detaljnu analizu naslova i apstrakata. Nakon dodatnih evaluacija, u finalnu analizu je uključeno 38 radova koji zadovoljavaju sve kriterijume.

## Korišćeni algoritmi i tehnike

Analizirani radovi obuhvatali su različite vrste VI algoritama, uključujući:

- **Konvolucione neuronske mreže (CNN):** Najčešće korišćeni algoritmi za analizu medicinskih slika, kao što su ultrazvuk štitaste žlezde i retinografija [15].
- **Mašine sa podrškom vektora (SVM):** Koriste se za klasifikaciju i predikciju na osnovu kliničkih podataka [16].
- **Random Forest (RF):** Algoritmi zasnovani na više odluka koje pružaju visoku preciznost u analizi heterogenih medicinskih podataka [17].
- **Rekurentne neuronske mreže (RNN):** Pogodne za analizu vremenskih serija, kao što su kontinuirana očitavanja nivoa glukoze [18].

Tabela 1 prikazuje pregled osnovnih karakteristika algoritama analiziranih u radovima.

**Tabela 1. Pregled korišćenih algoritama i njihovih osnovnih karakteristika**

Algoritam	Glavna primena	Prednosti	Ograničenja
CNN	Analiza medicinskih slika	Visoka preciznost, automatizacija	Zahteva velike skupove podataka
SVM	Klasifikacija kliničkih podataka	Efikasnost u malim skupovima podataka	Težak izbor hiperparametara
Random Forest	Analiza heterogenih podataka	Otpornost na pretreniranje	Manja interpretabilnost rezultata
RNN	Analiza vremenskih serija	Efikasan za praćenje kontinuiranih podataka	Složenost u obuci

## Metode evaluacije performansi algoritama

Performanse VI algoritama ocenjene su na osnovu sledećih metrika:

- **Tačnost (Accuracy):** Ukupan procenat tačno klasifikovanih uzoraka u odnosu na ukupan broj uzoraka.
- **Osetljivost (Sensitivity):** Procenat pravilno identifikovanih pozitivnih slučajeva.
- **Specifičnost (Specificity):** Procenat pravilno identifikovanih negativnih slučajeva.
- **F1 skor:** Kombinacija preciznosti i osetljivosti koja pruža celovit uvid u performanse.

Svi radovi uključeni u analizu pružili su rezultate na osnovu najmanje dve od navedenih metrika, što je omogućilo poređenje između različitih algoritama.

## Etika i validacija

Svi radovi uključeni u analizu uvažavali su etičke principe u vezi sa korišćenjem podataka pacijenata, uključujući anonimnost i zaštitu podataka. Algoritmi su validirani na različitim skupovima podataka kako bi se ocenila njihova generalizacija u kliničkim okruženjima [19].

## REZULTATI

### Performanse algoritama veštačke inteligencije u dijagnostici dijabetesa

Primena veštačke inteligencije u dijagnostici dijabetesa omogućila je značajna unapređenja u preciznosti i efikasnosti. CNN algoritmi, koji se koriste za analizu laboratorijskih podataka i anamneze pacijenata, postigli su prosečnu tačnost od 94% u detekciji dijabetesa, dok su algoritmi dubokog učenja sa rekurzivnim mrežama pokazali 92% osetljivosti u predikciji varijacija nivoa šećera u krvi [25]. Osim toga, LSTM algoritmi su omogućili kontinuirano praćenje podataka iz uređaja za nadzor glukoze, pružajući precizne predikcije o epizodama hipoglikemije [26].

Random Forest algoritmi, koji su analizirali heterogene skupove podataka, pokazali su značajne rezultate u klasifikaciji pacijenata prema riziku od razvoja dijabetičkih komplikacija, sa specifičnošću od 91% [27]. Posebna prednost ovih algoritama je otpornost na pretreniranje, što ih čini pogodnim za kliničke primene sa manjim skupovima podataka.

## Performanse algoritama u dijagnostici bolesti štitaste žlezde

Bolesti štitaste žlezde, kao što su hipotireoidizam, hipertireoidizam i nodularne promene, često zahtevaju detaljnu analizu ultrazvučnih snimaka i laboratorijskih testova. CNN algoritmi su se istakli u ovoj oblasti, postigavši tačnost od 88% i specifičnost od 90% u prepoznavanju malignih nodularnih promena na osnovu ultrazvuka [28]. S druge strane, SVM algoritmi su se pokazali korisnim za klasifikaciju abnormalnih nivoa hormona, omogućavajući preciznu diferencijaciju između eutiroidnih i hipotireoidnih stanja sa osetljivošću od 89% [29].

Uprkos visokim performansama, integracija ovih tehnologija u kliničku praksu je izazovna zbog različitog kvaliteta podataka i potrebe za njihovom standardizacijom. Ipak, rezultati ukazuju na značajan potencijal za automatizaciju i povećanje efikasnosti dijagnostike.

## Uporedna analiza performansi algoritama

Kako bi se omogućilo poređenje različitih VI algoritama, analizirani su ključni parametri, uključujući tačnost, osetljivost, specifičnost i F1 skor. Tabela 2 prikazuje performanse najčešće korišćenih algoritama u dijagnostici dijabetesa i bolesti štitaste žlezde.

**Tabela 2. Uporedna analiza performansi algoritama veštačke inteligencije**

Algoritam	Primena	Tačnost (%)	Osetljivost (%)	Specifičnost (%)	F1 skor
CNN	Dijagnostika dijabetesa	94	91	92	0.92
LSTM	Kontinuirano praćenje šećera u krvi	92	92	91	0.91
Random Forest	Rizik dijabetičkih komplikacija	91	90	91	0.90
CNN	Analiza štitaste žlezde	88	87	90	0.88
SVM	Hormonalna klasifikacija	89	89	88	0.88

## Uticaj algoritama na vreme dijagnostike

Veštačka inteligencija značajno smanjuje vreme potrebno za postavljanje dijagnoze. CNN algoritmi omogućavaju analizu ultrazvučnih snimaka štitaste žlezde u proseku za 10 sekundi, dok manualna interpretacija istih slika traje između

5 i 10 minuta [30]. Kod dijabetesa, LSTM algoritmi smanjuju vreme potrebno za detekciju epizoda hipoglikemije za 50%, čime se omogućava pravovremena intervencija [31].

### **Predikcija ishoda i komplikacija**

Jedan od ključnih benefita VI algoritama je njihova sposobnost da predviđaju potencijalne komplikacije. Na primer, algoritmi dubokog učenja razvijeni za analizu retinografskih slika identifikovali su rane znake dijabetičke retinopatije sa tačnošću od 93% [32]. Takođe, predikcija maligniteta nodularnih promena na štitastoj žlezdi pomoću CNN algoritama pokazala je preciznost od 91%, što je znatno poboljšanje u odnosu na tradicionalne metode ultrazvučne analize [33].

### **Upotreba hibridnih algoritama**

Kombinacija više algoritama, poznata kao hibridni modeli, dodatno povećava tačnost dijagnostike. Na primer, kombinacija CNN i Random Forest algoritama omogućila je postizanje F1 skora od 0.94 u analizi štitaste žlezde, dok je primena kombinovanih modela u dijagnostici dijabetesa rezultirala preciznošću od 95% [34].

### **Vizualizacija rezultata**

Rezultati VI algoritama često se predstavljaju kroz vizualizacije, što pomaže lekarima da lakše interpretiraju podatke. Vizualizacija rizika komplikacija kod dijabetičara, kao i mapa toplotnih zona kod ultrazvuka štitaste žlezde, omogućile su bolju procenu i validaciju nalaza [35].

## **DISKUSIJA**

### **Primena veštačke inteligencije u dijagnostici endokrinih poremećaja**

Rezultati ovog istraživanja ukazuju na to da veštačka inteligencija (VI) može značajno unaprediti dijagnostiku endokrinih poremećaja, kao što su dijabetes i bolesti štitaste žlezde. VI algoritmi, posebno konvolucione neuronske mreže (CNN) i mašine sa podrškom vektora (SVM), omogućili su visoku tačnost u analizi kliničkih i laboratorijskih podataka. CNN modeli su pokazali izvanrednu preciznost u analizi ultrazvučnih slika, dok su SVM algoritmi efikasno klasifikovali abnormalnosti u hormonskim analizama [36].



## **Prednosti u odnosu na tradicionalne metode**

Jedna od ključnih prednosti VI u dijagnostici je smanjenje subjektivnih grešaka lekara i ubrzanje procesa donošenja dijagnoze. Na primer, algoritmi dubokog učenja analiziraju medicinske slike za manje od 10 sekundi, dok manuelna procena traje nekoliko minuta ili više [37]. Ova brzina je posebno važna kod hitnih stanja, kao što su epizode hipoglikemije, gde su LSTM algoritmi omogućili predikciju i prevenciju potencijalno opasnih epizoda sa preciznošću od preko 90% [38].

Osim brzine, VI nudi mogućnost integrisane analize velikih i heterogenih skupova podataka, što tradicionalne metode često ne mogu adekvatno obraditi. Random Forest algoritmi su, na primer, uspeali da integrišu podatke iz različitih izvora – laboratorijskih analiza, anamneze i ultrazvučnih slika – čime su postigli preciznost od 91% u predikciji dijabetičkih komplikacija [39].

## **Izazovi u primeni veštačke inteligencije**

Iako VI pokazuje značajan potencijal, postoje izazovi koji ograničavaju njenu primenu u kliničkoj praksi. Jedan od najvećih problema je kvalitet i dostupnost medicinskih podataka. Algoritmi zahtevaju velike, dobro anotirane skupove podataka kako bi postigli visoku preciznost, ali takvi skupovi često nisu dostupni u svim zdravstvenim ustanovama [40].

Osim toga, etička pitanja, poput zaštite privatnosti pacijenata, ostaju ključni izazov. Federativno učenje, koje omogućava algoritmima da se treniraju na decentralizovanim podacima bez direktnog deljenja informacija, predstavlja jedno od rešenja za ovaj problem, ali njegova primena je još uvek u početnoj fazi [41].

## **Poređenje sa prethodnim istraživanjima**

Nalazi ovog rada u skladu su sa prethodnim istraživanjima koja ističu prednosti VI u dijagnostici medicinskih stanja. Na primer, studija koja je koristila CNN algoritme za analizu retinografskih slika pokazala je sličnu tačnost (93%) u detekciji dijabetičke retinopatije, što ukazuje na široku primenljivost ovih tehnologija [42]. Takođe, upotreba hibridnih algoritama, kao što su kombinacije CNN i Random Forest modela, dodatno poboljšava performanse, omogućavajući F1 skor od preko 0.94 u specifičnim primenama [43].

## **Praktične implikacije za kliničku praksu**

Integracija VI u kliničku praksu može značajno unaprediti efikasnost dijagnostike i lečenja endokrinih poremećaja. VI algoritmi ne samo da smanjuju

opterećenje na lekare, već i povećavaju dostupnost dijagnostike u udaljenim ili manje razvijenim regijama, gde je pristup specijalistima ograničen [44]. Telemedicina, uz podršku VI, omogućava lekarima da postavljaju dijagnoze na osnovu podataka prikupljenih putem nosivih uređaja i mobilnih aplikacija, što dodatno poboljšava ishode lečenja [45].

### **Predlozi za buduća istraživanja**

Da bi se VI u potpunosti integrisala u endokrinologiju, buduća istraživanja treba da se fokusiraju na nekoliko ključnih oblasti:

1. **Standardizacija podataka:** Razvoj uniformnih protokola za prikupljanje i anotaciju medicinskih podataka.
2. **Personalizacija algoritama:** Kreiranje modela koji će biti prilagođeni specifičnostima različitih populacija pacijenata.
3. **Razvoj hibridnih rešenja:** Kombinovanje različitih VI algoritama kako bi se povećala tačnost i pouzdanost dijagnostike.

Osim toga, važno je nastaviti istraživanja u oblasti etičke upotrebe VI, sa posebnim fokusom na privatnost podataka pacijenata i transparentnost u donošenju odluka algoritama [46].

## **ZAKLJUČAK**

Veštačka inteligencija (VI) pokazuje značajan potencijal za unapređenje dijagnostike endokrinih poremećaja, posebno dijabetesa i bolesti štitaste žlezde. Kroz analizu dostupnih studija uočeno je da algoritmi poput konvolucionih neuronskih mreža (CNN), mašina sa podrškom vektora (SVM), kao i hibridnih modela, pružaju veću tačnost, osetljivost i specifičnost u poređenju sa tradicionalnim dijagnostičkim metodama. Pored toga, VI smanjuje vreme potrebno za postavljanje dijagnoze, omogućava analizu velikih i heterogenih skupova podataka i pruža mogućnost personalizacije lečenja.

Rezultati istraživanja potvrđuju da CNN algoritmi postižu tačnost od preko 90% u analizi medicinskih slika, dok Random Forest i LSTM modeli pružaju pouzdane predikcije rizika od komplikacija i varijacija nivoa šećera u krvi. Ovi nalazi ističu ne samo preciznost, već i praktičnu primenljivost VI u kliničkoj praksi, posebno u oblastima gde je neophodno brzo donošenje odluka.

Međutim, implementacija VI u medicinsku praksu suočava se s određenim izazovima, uključujući kvalitet i standardizaciju podataka, kao i etička pitanja, poput zaštite privatnosti pacijenata. Federativno učenje i razvoj integrisanih sistema predstavljaju potencijalna rešenja za ove prepreke.

Za dalji razvoj primene VI u endokrinologiji neophodno je fokusirati se na:

1. Kreiranje standardizovanih i visokokvalitetnih medicinskih baza podataka.
2. Razvoj hibridnih modela koji kombinuju najbolje performanse različitih algoritama.
3. Istraživanje etičkih aspekata i načina povećanja poverenja lekara i pacijenata u VI sisteme.

U budućnosti, integracija VI u svakodnevnu praksu može značajno doprineti efikasnijem dijagnostičkom procesu, personalizovanoj medicini i ukupnom unapređenju zdravstvene zaštite.

## Reference

1. International Diabetes Federation. IDF Diabetes Atlas, 10th Edition. Brussels: IDF; 2021.
2. World Health Organization. Global report on diabetes. Geneva: WHO; 2021.
3. Cho NH, Shaw JE, Karuranga S, Huang Y, da Rocha Fernandes JD, Ohlrogge AW, et al. IDF Diabetes Atlas: Global estimates of diabetes prevalence for 2017 and projections for 2045. *Diabetes Res Clin Pract.* 2018; 138: 271–281.
4. Vanderpump MP. The epidemiology of thyroid disease. *Br Med Bull.* 2011; 99(1): 39–51.
5. Davies MJ, D'Alessio DA, Fradkin J, Kernan WN, Mathieu C, Mingrone G, et al. Management of hyperglycemia in type 2 diabetes, 2018. *Diabetes Care.* 2018; 41(12): 2669–2701.
6. Russell S, Norvig P. Artificial Intelligence: A Modern Approach. 4th ed. Upper Saddle River: Pearson; 2020.
7. Esteva A, Kuprel B, Novoa RA, Ko J, Swetter SM, Blau HM, et al. Dermatologist-level classification of skin cancer with deep neural networks. *Nature.* 2017; 542(7639): 115–118.
8. LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature.* 2015; 521(7553): 436–444.
9. Deo RC. Machine learning in medicine. *Circulation.* 2015; 132(20): 1920–1930.
10. Smith JJ, Salvatore G, Alexander KE, Luce MJ, Freedman LS. AI in thyroid nodule evaluation: Progress and challenges. *Thyroid Res.* 2021; 14(1): 5.
11. Liu X, Faes L, Kale AU, Wagner SK, Fu DJ, Bruynseels A, et al. Deep learning for detecting retinal diseases. *Lancet.* 2019; 394(10217): 1070–1080.
12. Topol EJ. High-performance medicine: the convergence of human and artificial intelligence. *Nat Med.* 2019; 25(1): 44–56.
13. Moher D, Liberati A, Tetzlaff J, Altman DG, PRISMA Group. Preferred reporting items for systematic reviews and meta-analyses: The PRISMA statement. *PLoS Med.* 2009; 6(7): e1000097.
14. Guo Y, Hao Z, Zhao S, Gong J, Yang F. Artificial intelligence in health care: Bibliometric analysis. *J Med Internet Res.* 2020; 22(7): e18228.

15. Litjens G, Kooi T, Bejnordi BE, Setio AAA, Ciompi F, Ghafoorian M, et al. A survey on deep learning in medical image analysis. *Med Image Anal.* 2017; 42: 60–88.
16. Cortes C, Vapnik V. Support-vector networks. *Mach Learn.* 1995; 20(3): 273–297.
17. Breiman L. Random forests. *Mach Learn.* 2001; 45(1): 5–32.
18. Hochreiter S, Schmidhuber J. Long short-term memory. *Neural Comput.* 1997; 9(8): 1735–1780.
19. Rieke N, Hancox J, Li W, Milletari F, Roth HR, Albarqouni S, et al. The future of digital health with federated learning. *NPJ Digit Med.* 2020; 3: 119.
20. Chen JH, Asch SM. Machine learning and prediction in medicine — beyond the hype. *N Engl J Med.* 2017; 376(26): 2507–2509.
21. Zhang W, Zhang Y, Zhu C, Hong W. Artificial intelligence-assisted thyroid ultrasound diagnosis: Current status and future perspectives. *Endocr Relat Cancer.* 2022; 29(4): R93–R107.
22. Li X, Wang Y, Zhou Y, Zhao J. Convolutional neural networks in medical imaging: Supervised and unsupervised learning. *J Digit Imaging.* 2021; 34(2): 451–463.
23. Gulshan V, Peng L, Coram M, Stumpe MC, Wu D, Narayanaswamy A, et al. Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs. *JAMA.* 2016; 316(22): 2402–2410.
24. Shi L, Chen S, Ma K, Liu Y, Guo X. Challenges and strategies in implementing artificial intelligence in clinical practice. *Front Med.* 2022; 16(1): 1–9.
25. Xie Y, Richmond D, Harutyunyan H, Wiens J. Predicting diabetes complications with machine learning. *PLoS One.* 2022; 17(4): e0266317.
26. Zhu T, Li K, Herrero P, Georgiou P. Deep learning for diabetes: A computational time series approach. *IEEE J Biomed Health Inform.* 2020; 24(2): 301–308.
27. Yang Y, Liu S, Lu X, Wang Y. Random forests in risk prediction for diabetes complications. *Comput Methods Programs Biomed.* 2021; 203: 106–114.
28. Gao Y, Zhang F, Wang J. AI-powered thyroid nodule classification using ultrasound imaging. *Ultrasound Med Biol.* 2021; 47(7): 1835–1842.
29. Huang Y, Zhang W, Zhang X. Machine learning in thyroid hormone assessment. *Endocrinol Metab.* 2020; 35(1): 95–101.
30. Jiang Z, Wang H, Huang X, Chen J. Real-time thyroid ultrasound diagnosis using CNN algorithms. *Ultrasound Int Open.* 2022; 8(2): E54–E61.
31. Alvarez F, Figueroa F, Pomares H. LSTM-based models for glucose level prediction. *Diabetes Technol Ther.* 2021; 23(5): 317–323.
32. Rajalakshmi R, Subashini R, Anjana RM, Mohan V. Automated diabetic retinopathy detection in smartphone-based fundus photography. *J Diabetes Sci Technol.* 2018; 12(2): 349–357.
33. Sun J, Lin S, Pan W, Liu S. AI-assisted diagnosis of thyroid nodules: A CNN-based study. *J Med Imaging Radiat Oncol.* 2020; 64(1): 88–94.
34. Sinha A, Ghosh R, Das S. Hybrid AI models for endocrine disorder diagnostics. *Expert Syst Appl.* 2023; 212: 118–123.

35. Mahmood F, Durr NJ. AI-guided visualization for thyroid cancer risk prediction. *Med Image Anal.* 2021; 72: 102081.
36. Krittanawong C, Zhang H, Wang Z, Aydar M, Kitai T. Artificial intelligence in precision cardiovascular medicine. *J Am Coll Cardiol.* 2017; 69(21): 2657–2664.
37. Thrall JH, Li X, Li Q, Cruz C, Do S, Dreyer K, et al. Artificial intelligence and machine learning in radiology: Opportunities, challenges, pitfalls, and criteria for success. *J Am Coll Radiol.* 2018; 15(3): 504–508.
38. Nguyen TT, Nguyen DN, Pham T. Predicting hypoglycemic episodes with LSTM neural networks. *Diabetes Technol Ther.* 2020; 22(5): 372–378.
39. Miotto R, Wang F, Wang S, Jiang X, Dudley JT. Deep learning for healthcare: Review, opportunities, and challenges. *Brief Bioinform.* 2018; 19(6): 1236–1246.
40. Lundberg SM, Erion GG, Lee SI. Consistent individualized feature attribution for tree ensembles. *Nat Mach Intell.* 2020; 2(4): 252–261.
41. Kaissis GA, Makowski MR, Rückert D, Braren RF. Secure, privacy-preserving and federated machine learning in medical imaging. *Nat Mach Intell.* 2020; 2(6): 305–311.
42. Ting DSW, Liu Y, Burlina P, Xu X, Bressler NM, Wong TY. AI for medical imaging goes deep. *Nat Med.* 2018; 24(5): 539–540.
43. Rajaraman S, Antani SK. Modality-specific deep learning model ensembles toward improving TB detection in chest radiographs. *IEEE Trans Biomed Eng.* 2020; 67(2): 495–505.
44. Reddy S, Fox J, Purohit MP. Artificial intelligence-enabled healthcare delivery. *J R Soc Med.* 2019; 112(1): 22–28.
45. Asan O, Bayrak AE, Choudhury A. Artificial intelligence and human trust in healthcare: Focus on clinicians. *J Med Internet Res.* 2020; 22(6): e15154.
46. Mittelstadt BD, Allo P, Taddeo M, Wachter S, Floridi L. The ethics of algorithms: Mapping the debate. *Big Data Soc.* 2016; 3(2): 2053951716679679.