

Maske ne obvarujejo pred virusi. Ali pač?

Avtomatsko ugotavljanje kakovosti

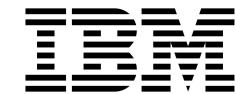
izsledkov v medicini

Simon Šuster

Seminar JOTA

5. junij 2023





Objave

[1] Šuster S, Baldwin T, Lau, JH, Jimeno Yepes A, Martinez Iraola D, Otmakhova Y, Verspoor K. (2023) Automating Quality Assessment of Medical Evidence in Systematic Reviews. *Journal of Medical Internet Research* 2023, e35568. DOI: [10.2196/35568](https://doi.org/10.2196/35568)

[2] Šuster S, Baldwin T, Verspoor K*. (2023) Analysis of predictive performance and reliability of classifiers for quality assessment of medical evidence revealed important variation by medical area. *Journal of Clinical Epidemiology*. DOI: [10.1016/j.jclinepi.2023.04.006](https://doi.org/10.1016/j.jclinepi.2023.04.006)

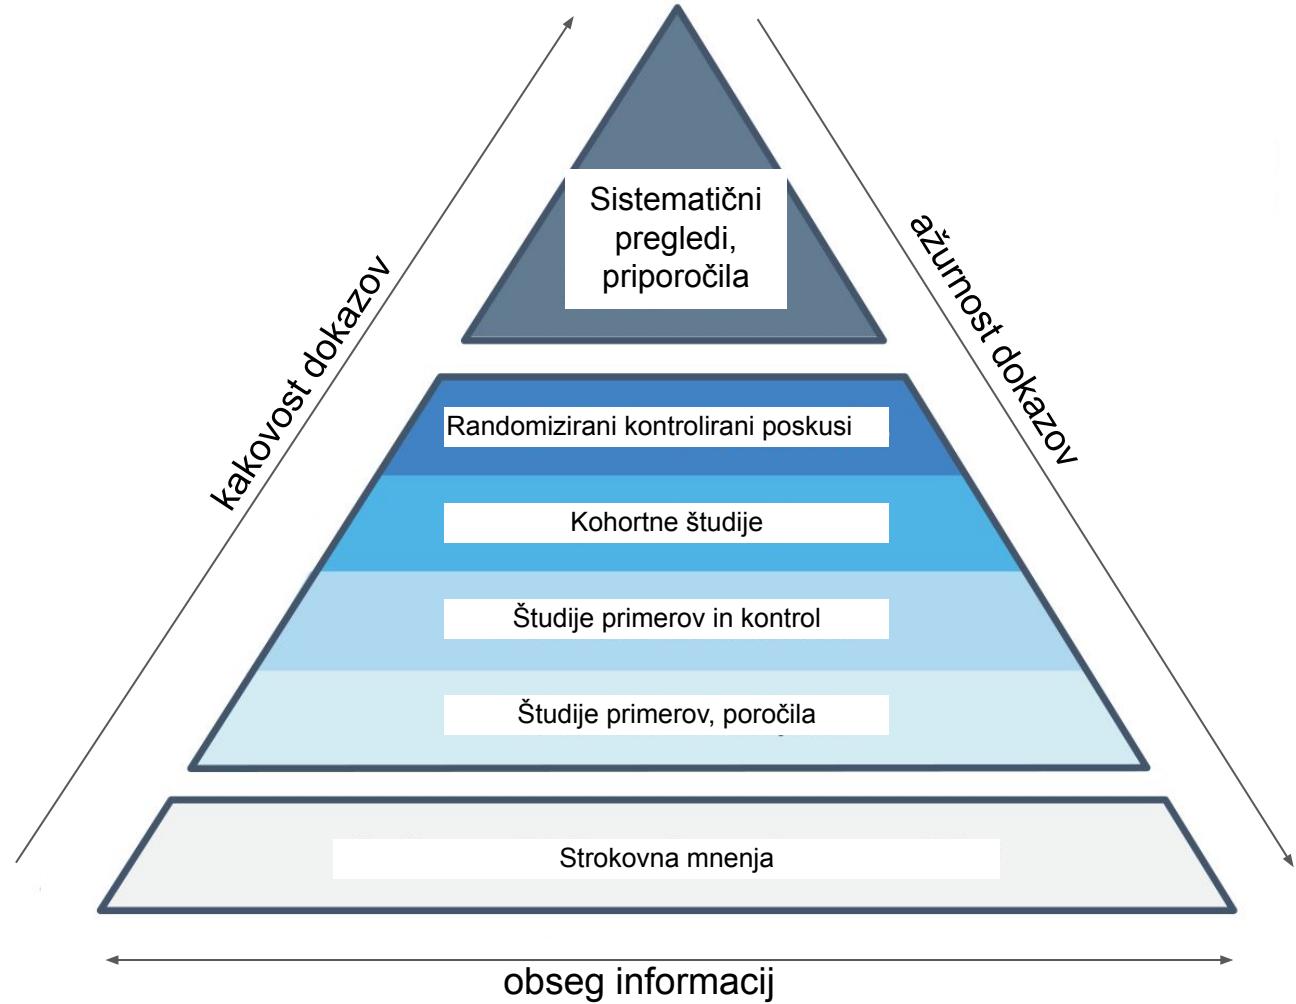
[3] Šuster S, Baldwin T, Verspoor K. (2023) Does Promoting Fairness in Classification of Quality of Medical Evidence Work? *BioNLP, ACL*.

Na dokazih temelječa medicina (Evidence-based medicine)

Klinično odločanje naj temelji na znanstvenih izsledkih, vendar:

1. znanstveni izsledki sami še ne zadoščajo za klinično odločanje (vrednotenje)
2. postavljeni morajo biti v ustrezeno hierarhijo

Ravni dokazov



Physical interventions to interrupt or reduce the spread of respiratory viruses

Tom Jefferson, Liz Dooley, Eliana Ferroni, Lubna A Al-Ansary, Mieke L van Driel, Ghada A Bawazeer, Mark A Jones, Tammy C Hoffmann, Justin Clark, Elaine M Beller, Paul P Glasziou,  John M Conly Authors' declarations of interest

Version published: 30 January 2023 Version history

<https://doi.org/10.1002/14651858.CD006207.pub6> 

Glavni izsledek:

→ "rezultati randomiziranih kontroliranih poskusov (RKP) niso pokazali jasnega zmanjšanja respiratornih virusnih okužb zaradi uporabe medicinskih/kirurških mask."

Obrazložitev:

→ "obstaja negotovost glede učinkov, ki jih ima nošenje obraznih mask. Nizka do srednja dokazna gotovost pomeni, da je naše zaupanje v ocenjen učinek omejeno in da se ta v resnici lahko razlikuje"

→ "**Zaradi visokega tveganja za pristranskost v poskusih, razlik v merjenju izidov in relativne nizke sodelovalnosti ni mogoče priti do trdnih zaključkov**"

→ "potrebnih je več kakovostnih RKP, s katerimi bi lahko ovrednotili najbolj učinkovite strategije za uspešno izvajanje fizičnih posegov v praksi [...] več prizadevanj, strožje načrtovanje in povečano financiranje za visokokakovostne RKP žal niso bili zagotovljeni v trenutni pandemiji covid-19 [...] Več poudarka bi moralo biti na opisovanju in oceni škod, nastalih zaradi posegov, vključenih v ta pregled, ter na njihovem razmerju s sodelovalnostjo."

Na dokazih temelječa podpora odločjanju



klinični scenarij



klinični primer

- povezati značilnosti pacienta s kriteriji za vključitev, opredeljenimi v smernicah
- uporabiti povzetke ali neposredna klinična vprašanja

predlagati relevantne smernice (IR & NLP)

smernice
(priporočila za specifično vprašanje)

povzemanje



medicinska literatura

raziskovanje
in izbor



relevantne študije
(RKP, opazovalne, ...)



sistematični pregledi

ocena
kakovosti

IR &
NLP

klinično vprašanje
po tehniki PICO:

Population/**P**roblem (populacija)
Intervention (poseg)
Comparison (primerjalni poseg)
Outcome (izid)

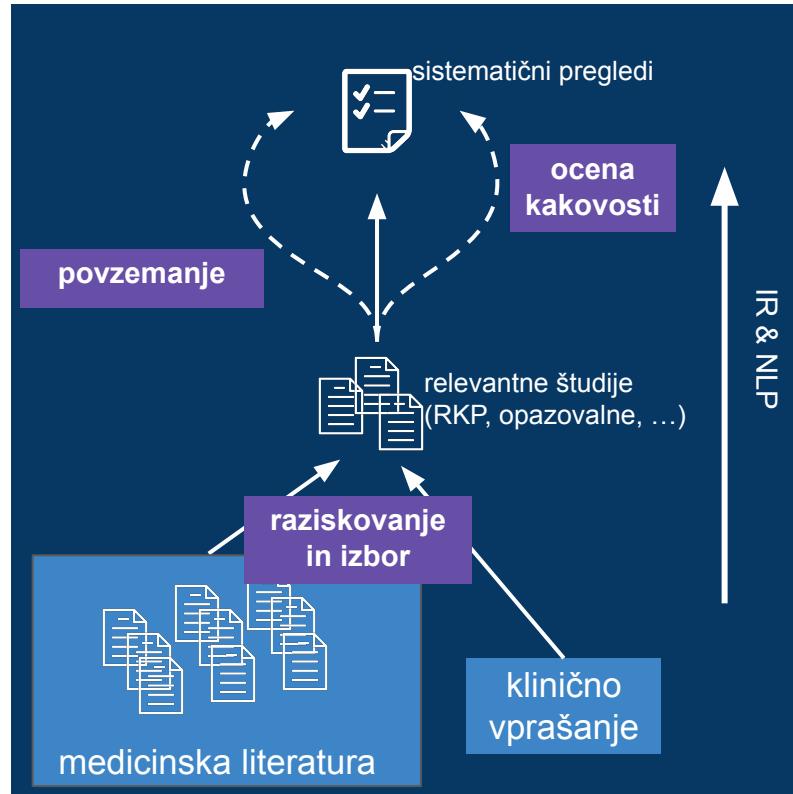
Zakaj avtomatizirati

Sistematicni pregledi hitro zastarajo:

- izredno zamudna izdelava (1–2 leti)
- naraščajoče število objav primarnih študij

Kako pospešiti proces izdelave s strojnim učenjem:

- doslej poudarek na iskanju in presejanju
- ocenjevanje kakovosti omejeno na zaznavanje tveganja za pristranskost v posamičnih študijah



Mesečni prirast člankov o covidu-19

LitCovid Data

352,326

Publications

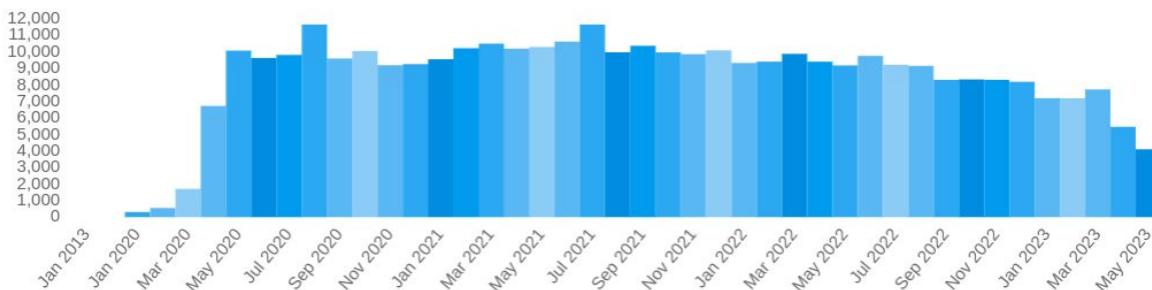
8

Topics

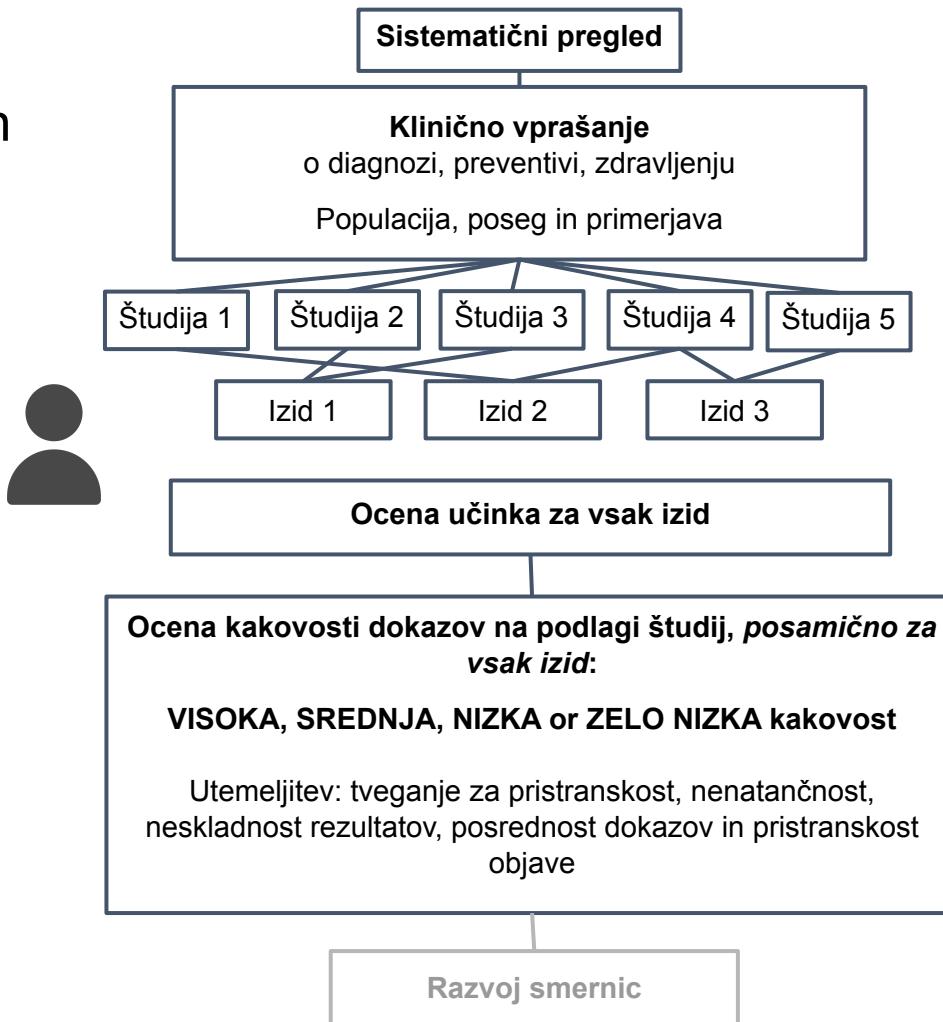
8,000

Journals

Monthly Publications

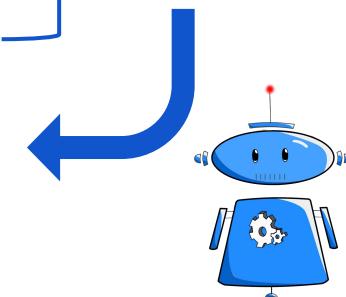


Priprava sistematičnih pregledov in ocenjevanje kakovosti



**Naš cilj
(EvidenceGRADEr):**

Na podlagi skupka
dokazov napovedati
njihovo kakovost



**Podatkovna množica + naloge +
modeli s heterogenimi vhodnimi
podatki (strukturiranimi in
nestrukturiranimi)**

Kakovost dokazov po protokolu GRADE (Grading of Recommendations Assessment, Development and Evaluation)

Randomizirana
kontrolirana
študija: VISOKA

Znižanje ocene zaradi:

- Tveganja za pristranskost
- Nenatančnosti
- Neskladnosti
- Posrednosti
- Pristranskosti objave

Končna ocena:

Visoka
Srednja
Nizka
Zelo nizka

Priporočilo (z
upoštevanje
dodatnih
dejavnikov)

Preglednica 5: Pristop GRADE – kakovost dokazov in glavni kriteriji za določanje jakosti priporočil.

Kakovost dokazov

++++	visoka	nadaljnje raziskave najverjetneje ne bodo spremenile našega zaupanja v ocenjeni učinek = prepričani smo, da je dejanski učinek v bližini ocenjenega
+++	srednja	nadaljnje raziskave bodo verjetno pomembno vplivale na naše zaupanje v ocenjeni učinek in lahko oceno spremenijo = dejanski učinek je najbrž blizu ocenjenemu, možno pa je tudi, da se od njega bistveno razlikuje
++	nizka	nadaljnje raziskave bodo zelo verjetno pomembno vplivale na naše zaupanje v ocenjeni učinek in bodo oceno verjetno spremenile = dejanski učinek se lahko bistveno razlikuje od ocenjenega
+	zelo nizka	kakršnakoli ocena učinka je zelo negotova

Jakost priporočil bodisi močna bodisi šibka – glede na

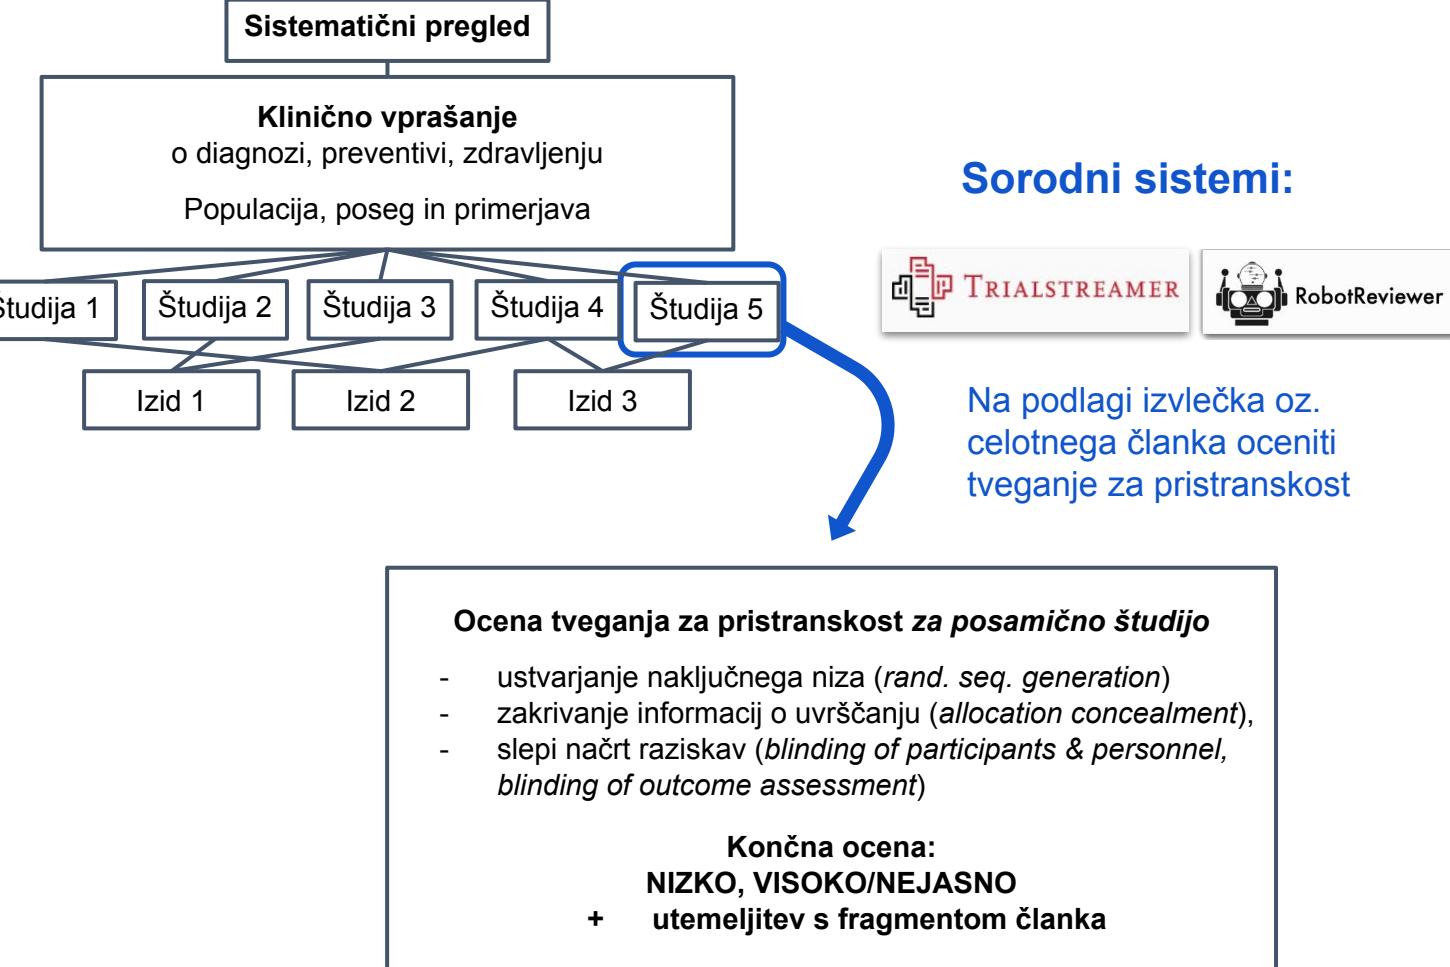
različen pomen različnih izidov (večjega naj imajo pomembnejši)

razmerje med želenimi in neželenimi učinki zdravljenja

enotnost (gotovost) oziroma raznolikost (negotovost) vrednot in izbir zdravljenja

stroške (potrebna sredstva)

Zaznavanje tveganja za pristranskost v sklopu sistematičnih pregledov



Priprava podatkov



Interventions for restoring patient catheter lumens
Last updated: 01 March 2021
DOI: 10.1002/14651858.CD000001.pub2
Abstract
Background
Objectives
Search methods
Selection criteria
Data collection and analysis
Main results

Pharmacological interventions for cognitive decline in people with Down syndrome
Last updated: 01 March 2021
DOI: 10.1002/14651858.CD000002.pub2
Abstract
Background
Objectives
Search methods
Selection criteria
Data collection and analysis
Main results

~7,000
sistematicnih
preglednih
člankov
(2010–2020)

Luščenje podatkov o kritični presoji iz povzetkov v tabelah in besedilu

Summary of findings					
Open in table viewer					
Summary of findings 1: Wheat flour fortified with iron alone compared to unfortified wheat flour (no micronutrients added) for reducing anaemia and improving iron status in populations					
Summary of findings for the included studies					
Patient or population characteristics for the included studies					
Intervention to compare (any active intervention)					
Outcomes					
Summary of findings 2: Comparison L: domperidol versus placebo					
Summary of findings for the main comparison: Comparison L: domperidol versus placebo					
Comparison L: domperidol versus placebo					
Setting: any					
Intervention: domperidol					
Comparison: domperidol					
Outcomes:					
Absolute effect (95% CI)					
Relative effect (95% CI)					
Number of participants (95% CI)					
Quality of the evidence (GRADE)					
Comments					
Resting patency					
Study population					
Age: 18 years					
Follow-up: 12 weeks					
Moderate					
Adverse effects					
Study population					
Age: 18 years					
Follow-up: 12–24 weeks					
Moderate					
Follow-up: 12 weeks					
Adverse events					
Study population					
Age: 18–65 years					
Follow-up: 12–24 weeks					
Moderate					
Harm/risks					
Follow-up: 12 weeks					
No data available					
Follow-up: 12–24 weeks					
No data available					
Follow-up: 12 weeks					
No data available					
Follow-up: 12–24 weeks					
No data available					
Follow-up: 12 weeks					
No data available					
Follow-up: 12–24 weeks					
No data available					
Follow-up: 12 weeks					
No data available					
Follow-up: 12–24 weeks					
No data available					
Follow-up: 12 weeks					
No data available					
Follow-up: 12–24 weeks					
No data available					
Follow-up: 12 weeks					
No data available					
Follow-up: 12–24 weeks					
No data available					
Follow-up: 12 weeks					
No data available					
Follow-up: 12–24 weeks					
No data available					
Follow-up: 12 weeks					
No data available					
Follow-up: 12–24 weeks					
No data available					
Follow-up: 12 weeks					
No data available					
Follow-up: 12–24 weeks					
No data available					
Follow-up: 12 weeks					
No data available					
Follow-up: 12–24 weeks					
No data available					
Follow-up: 12 weeks					
No data available					
Follow-up: 12–24 weeks					
No data available					
Follow-up: 12 weeks					
No data available					
Follow-up: 12–24 weeks					
No data available					
Follow-up: 12 weeks					
No data available					
Follow-up: 12–24 weeks					
No data available					
Follow-up: 12 weeks					
No data available					
Follow-up: 12–24 weeks					
No data available					
Follow-up: 12 weeks					
No data available					
Follow-up: 12–24 weeks					
No data available					
Follow-up: 12 weeks					
No data available					
Follow-up: 12–24 weeks					
No data available					
Follow-up: 12 weeks					
No data available					
Follow-up: 12–24 weeks					
No data available					
Follow-up: 12 weeks					
No data available					
Follow-up: 12–24 weeks					
No data available					
Follow-up: 12 weeks					
No data available					
Follow-up: 12–24 weeks					
No data available					
Follow-up: 12 weeks					
No data available					
Follow-up: 12–24 weeks					
No data available					
Follow-up: 12 weeks					
No data available					
Follow-up: 12–24 weeks					
No data available					
Follow-up: 12 weeks					
No data available					
Follow-up: 12–24 weeks					
No data available					
Follow-up: 12 weeks					
No data available					
Follow-up: 12–24 weeks					
No data available					
Follow-up: 12 weeks					
No data available					
Follow-up: 12–24 weeks					
No data available					
Follow-up: 12 weeks					
No data available					
Follow-up: 12–24 weeks					
No data available					
Follow-up: 12 weeks					
No data available					
Follow-up: 12–24 weeks					
No data available					
Follow-up: 12 weeks					
No data available					
Follow-up: 12–24 weeks					
No data available					
Follow-up: 12 weeks					
No data available					
Follow-up: 12–24 weeks					
No data available					
Follow-up: 12 weeks					
No data available					
Follow-up: 12–24 weeks					
No data available					
Follow-up: 12 weeks					
No data available					
Follow-up: 12–24 weeks					
No data available					
Follow-up: 12 weeks					
No data available					
Follow-up: 12–24 weeks					
No data available					
Follow-up: 12 weeks					
No data available					
Follow-up: 12–24 weeks					
No data available					
Follow-up: 12 weeks					
No data available					
Follow-up: 12–24 weeks					
No data available					
Follow-up: 12 weeks					
No data available					
Follow-up: 12–24 weeks					
No data available					
Follow-up: 12 weeks					
No data available					
Follow-up: 12–24 weeks					
No data available					
Follow-up: 12 weeks					
No data available					
Follow-up: 12–24 weeks					
No data available					

Tabele dokazov: pridobivanje oznak/pravih vrednosti in strukturiranih znacilk

Levosimendan compared with placebo for cardiogenic shock or low cardiac output syndrome

Patient or population: adults with cardiogenic shock or low cardiac output syndrome

Settings: hospital

Intervention: levosimendan

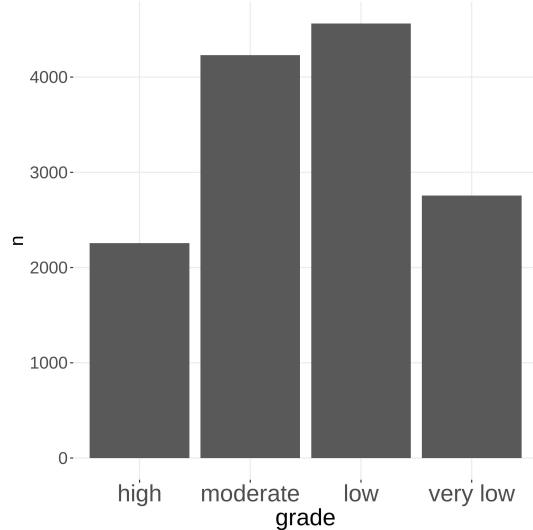
Comparison: placebo

Outcomes	Anticipated absolute effects (95% CI)		Relative effect (95% CI)	No of participants (studies)	Quality	Comments
	Risk with placebo	Risk with levosimendan				
All-cause short-term mortality: range 4 to 6 months	Moderate¹		RR 0.48 (0.12 to 1.94)	55 (2)	⊕⊕⊖	Studies included participants with LCOS or CS due to HF or AMI very low^{3,4}
	187 per 1000	90 per 1000 (22 to 363)				
	High²		500 per 1000	240 per 1000 (60 to 970)	⊕⊕⊕	Studies included participants with LCOS or CS due to HF or AMI very low^{3,4}
	500 per 1000					

³Downgraded one step due to study limitation because of lack of blinding of participants and physicians, and missing information on randomisation in the larger study.

⁴Downgraded two steps for imprecision due to few events and the confidence interval crosses the line of no difference and includes possible benefit from both approaches.

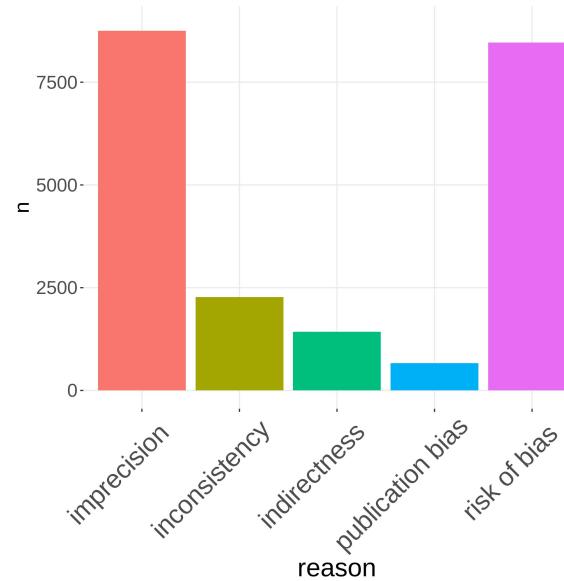
Porazdelitev podatkov



Kakovost dokazov je visoka le v ¼ primerov

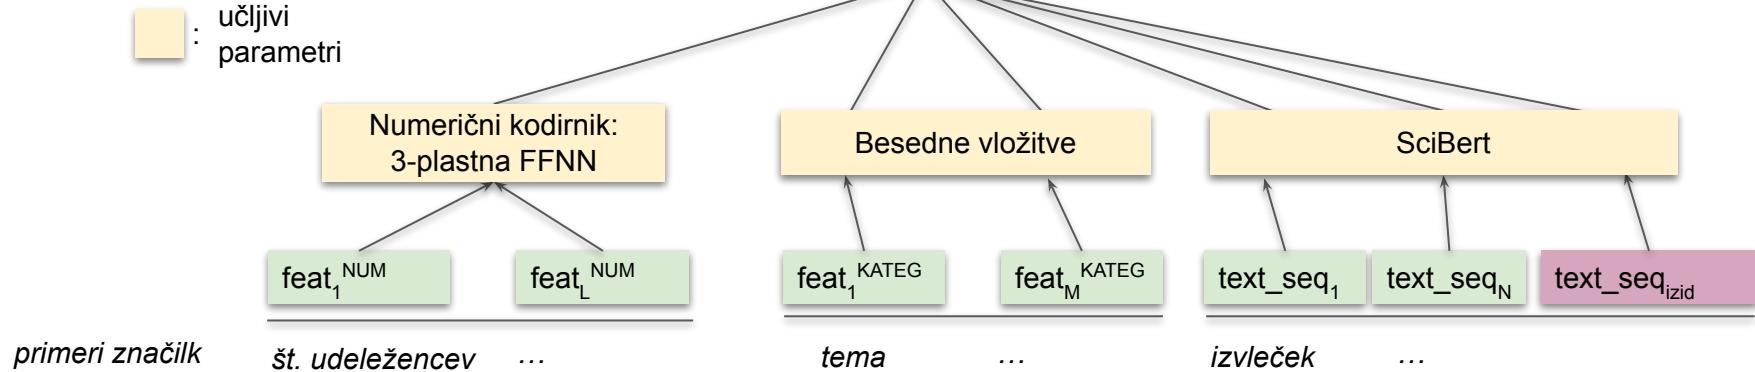
Polovica primerov je (zelo) nizke kakovosti

Ocena kakovosti dokazov se zniža zaradi:



EvidenceGRADEr

Osnovni model



Specifične naloge

naloge

Kriteriji kakovosti

Binarno ocenjevanje
GRADE

Ocenjevanje GRADE

izhodna
plast

Večznačna klasifikacija s
sigmoidi
(binarna križna entropija z
uteženimi razredi)

Klasifikacija (softmax)
(križna entropija)

Regresija: skalar v
razponu 0-3
(srednja kvadratna
napaka)

Rezultati za EvidenceGRADEr

(povprečne vrednosti iz 10-kratnega prečnega preverjanja)

Ocenjevanje GRADE

	F1	MAE
EvidenceGRADEr	0.49 (P: 0.54, R: 0.49)	0.62
naključna metoda	0.25	1.2
večinska metoda	0.13	0.8

možnost
arbitrarnih
razlik

sorodni
sistem

Binarno ocenjevanje GRADE

	F1
EvidenceGRADEr	0.74
naključna metoda	0.43
večinska metoda	0.46

poenostavljena
naloga

Kriteriji kakovosti

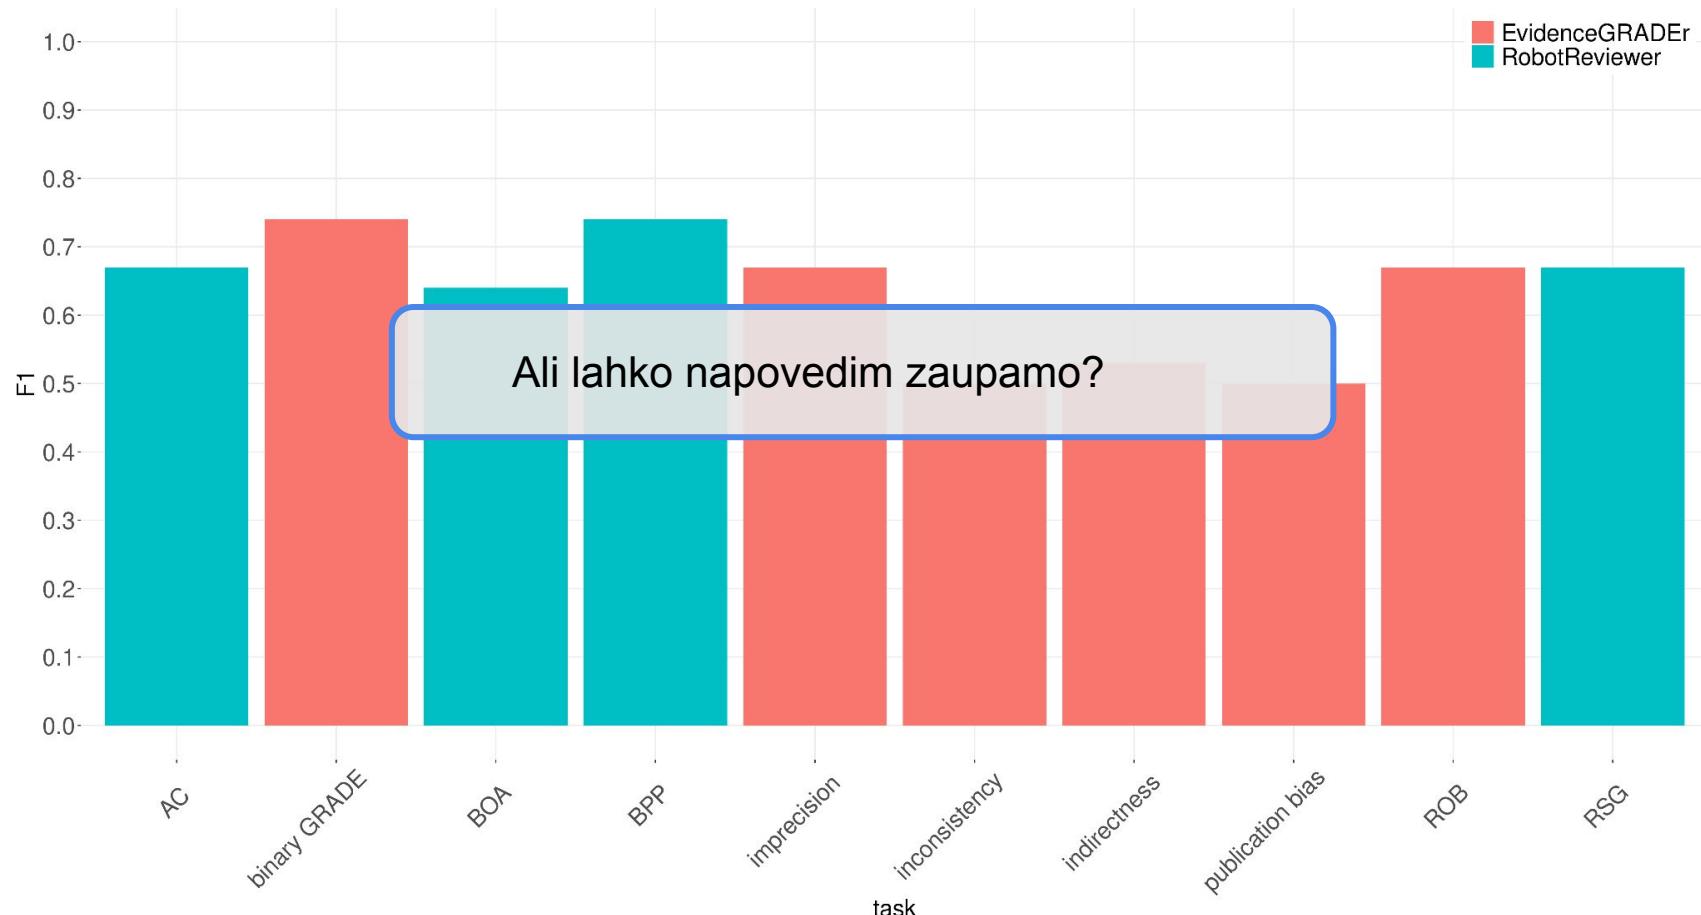
	F1
nenatančnost (<i>imprecision</i>)	0.63
tveganje za pristranskost (<i>risk of bias</i>)	0.70
neskladnost (<i>inconsistency</i>)	0.21
posrednost (<i>indirectness</i>)	0.26
pristranskost objave (<i>publication bias</i>)	0.11

RobotReviewer (naša reevalvacija)

	F1
random seq. generation	72.2
allocation concealment	66.5
blinding of participants	74.0
blinding of outcome assessment	62.6

določene
kategorije
so redke

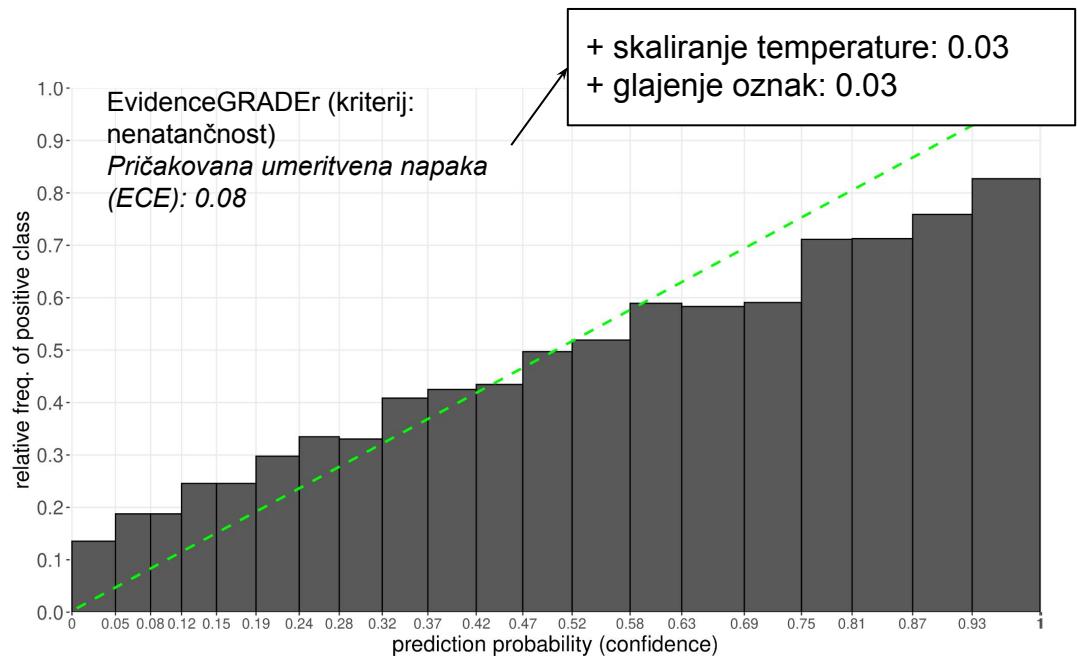
Uspešnost napovedovanja



Umerjanje klasifikatorjev

Pretirana gotovost nevronskih mrež

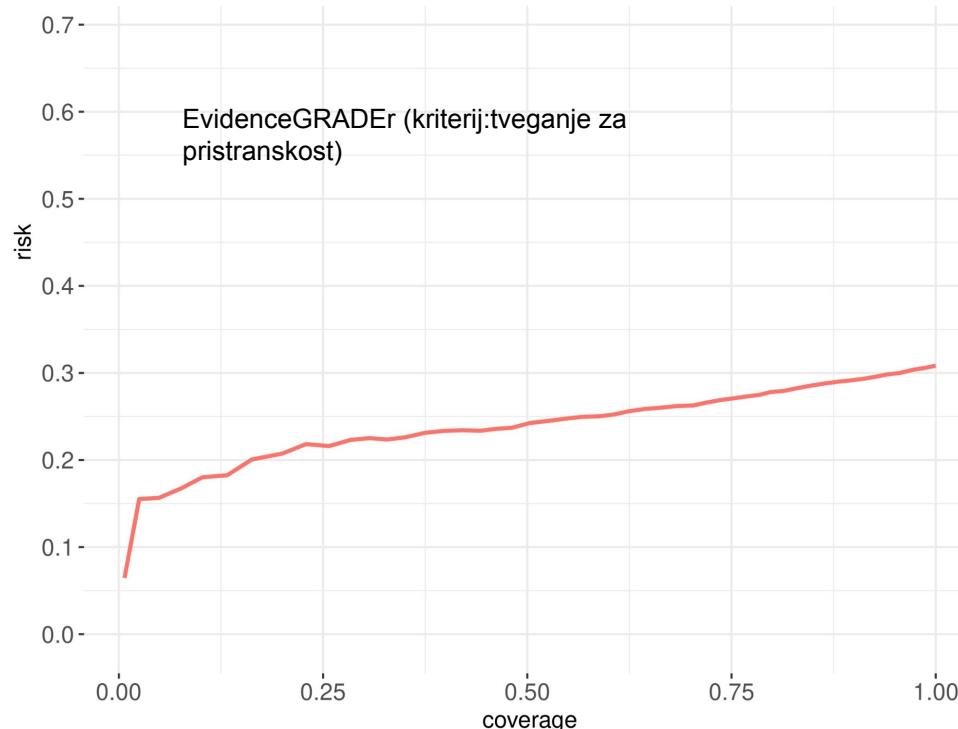
Model je zanesljiv, kadar ve, česar ne ve



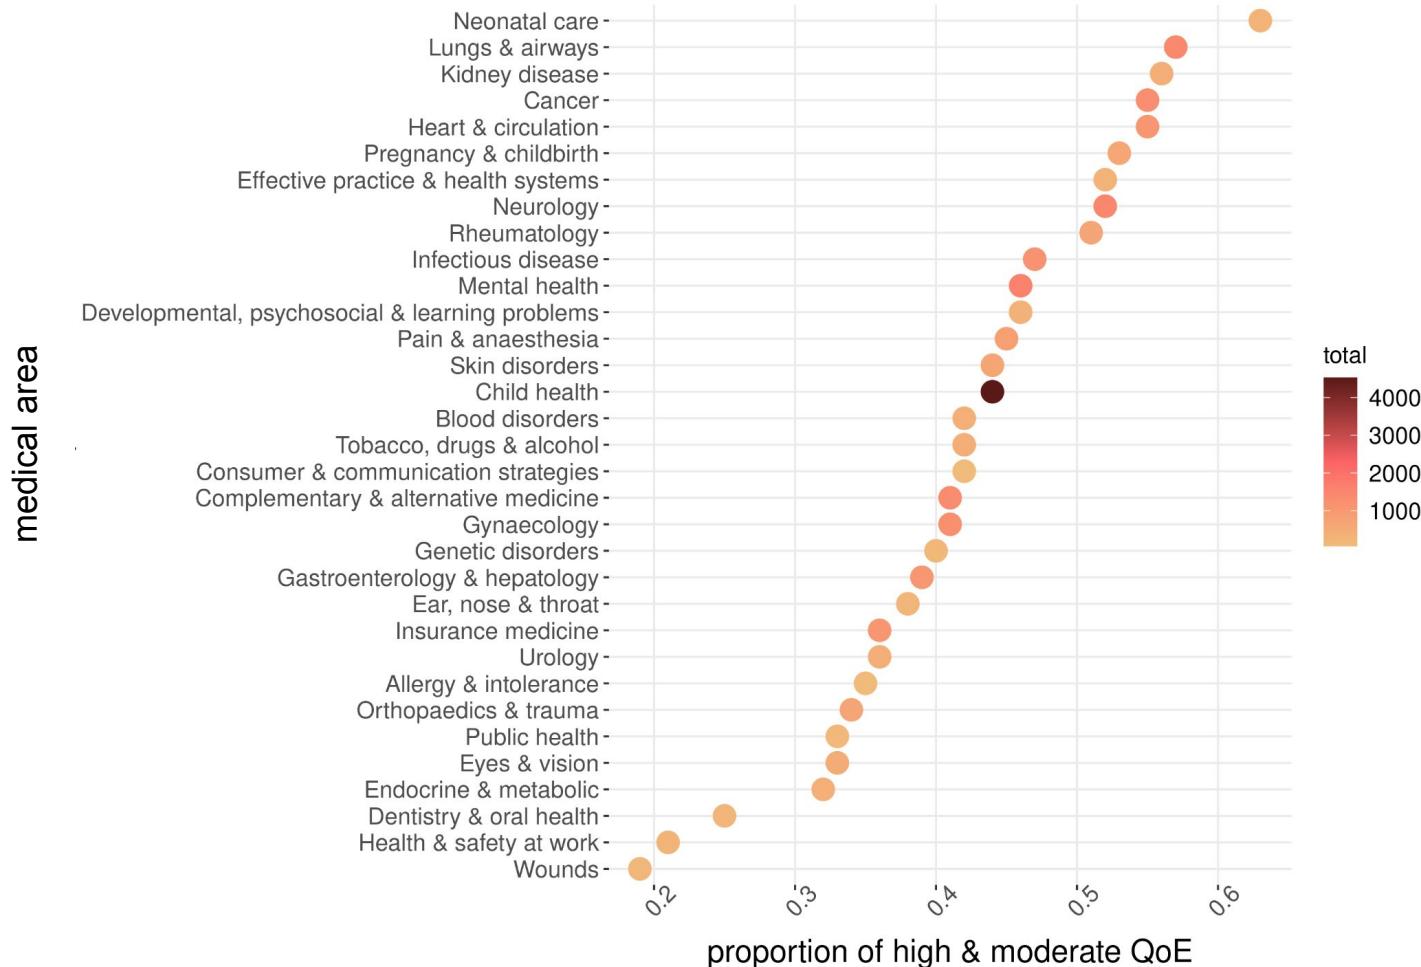
Izbirno napovedovanje (1/2)

Nekatere napovedi obdržimo, nekatere zavržemo

cilj: zmanjšati verjetje za napako ob hkratnem zmanjšanju pokritosti

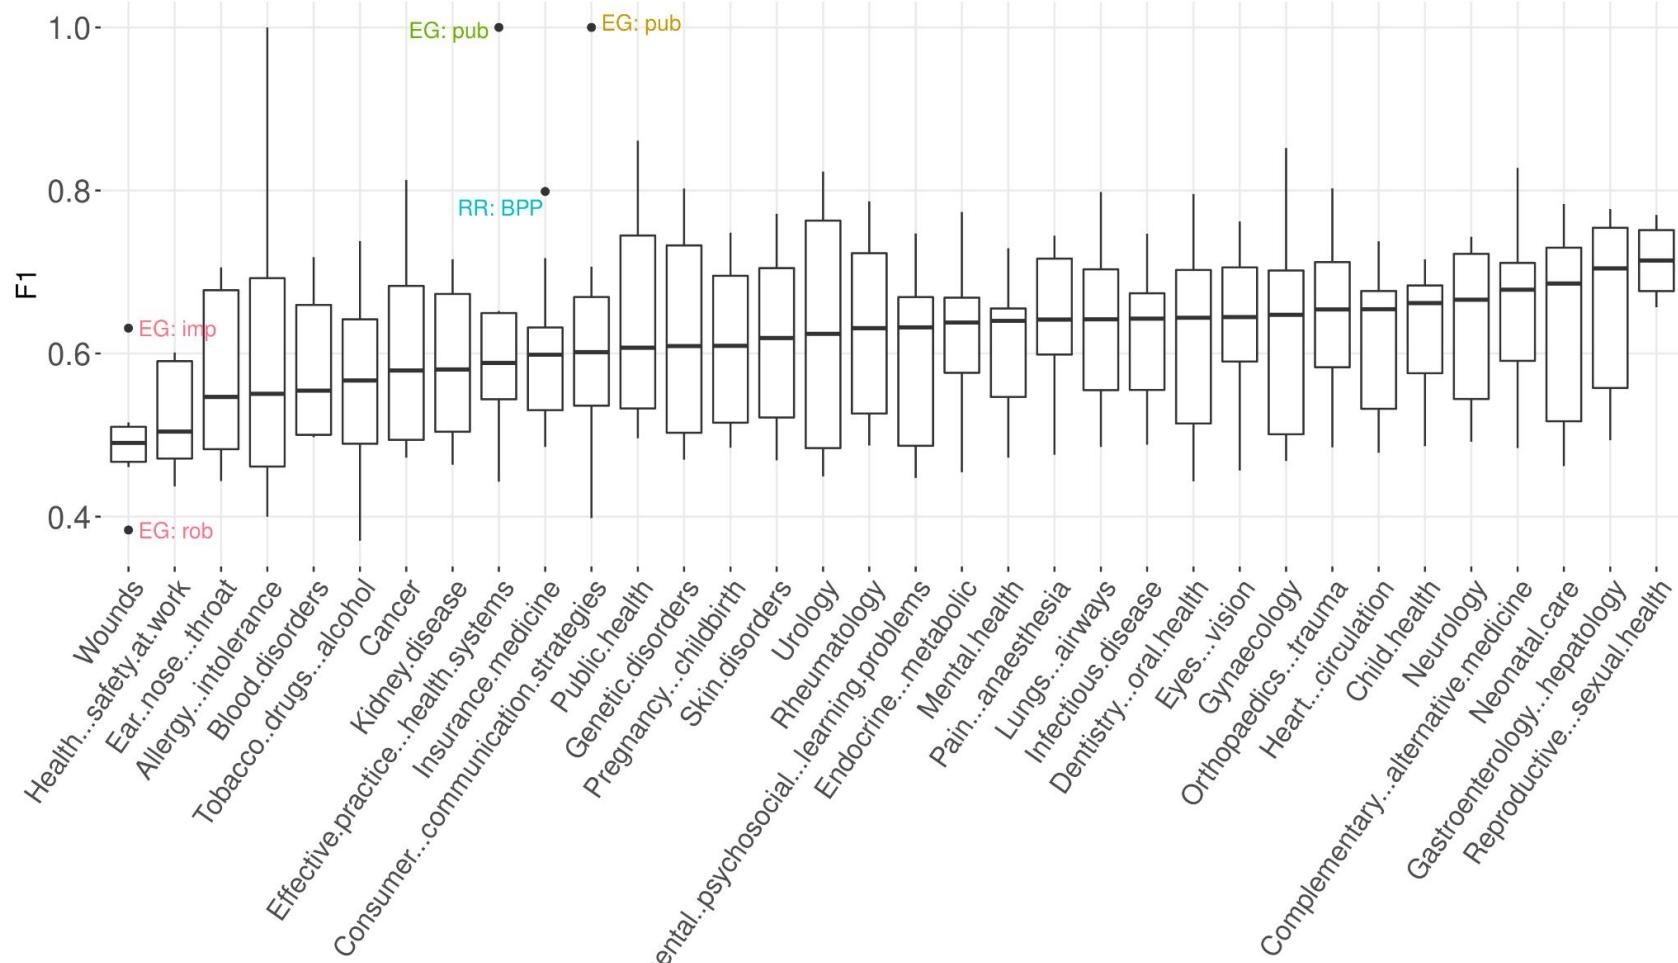


Nesorazmerje srednje-/visokokakovostnih dokazov v sist. pregledih Cochrane



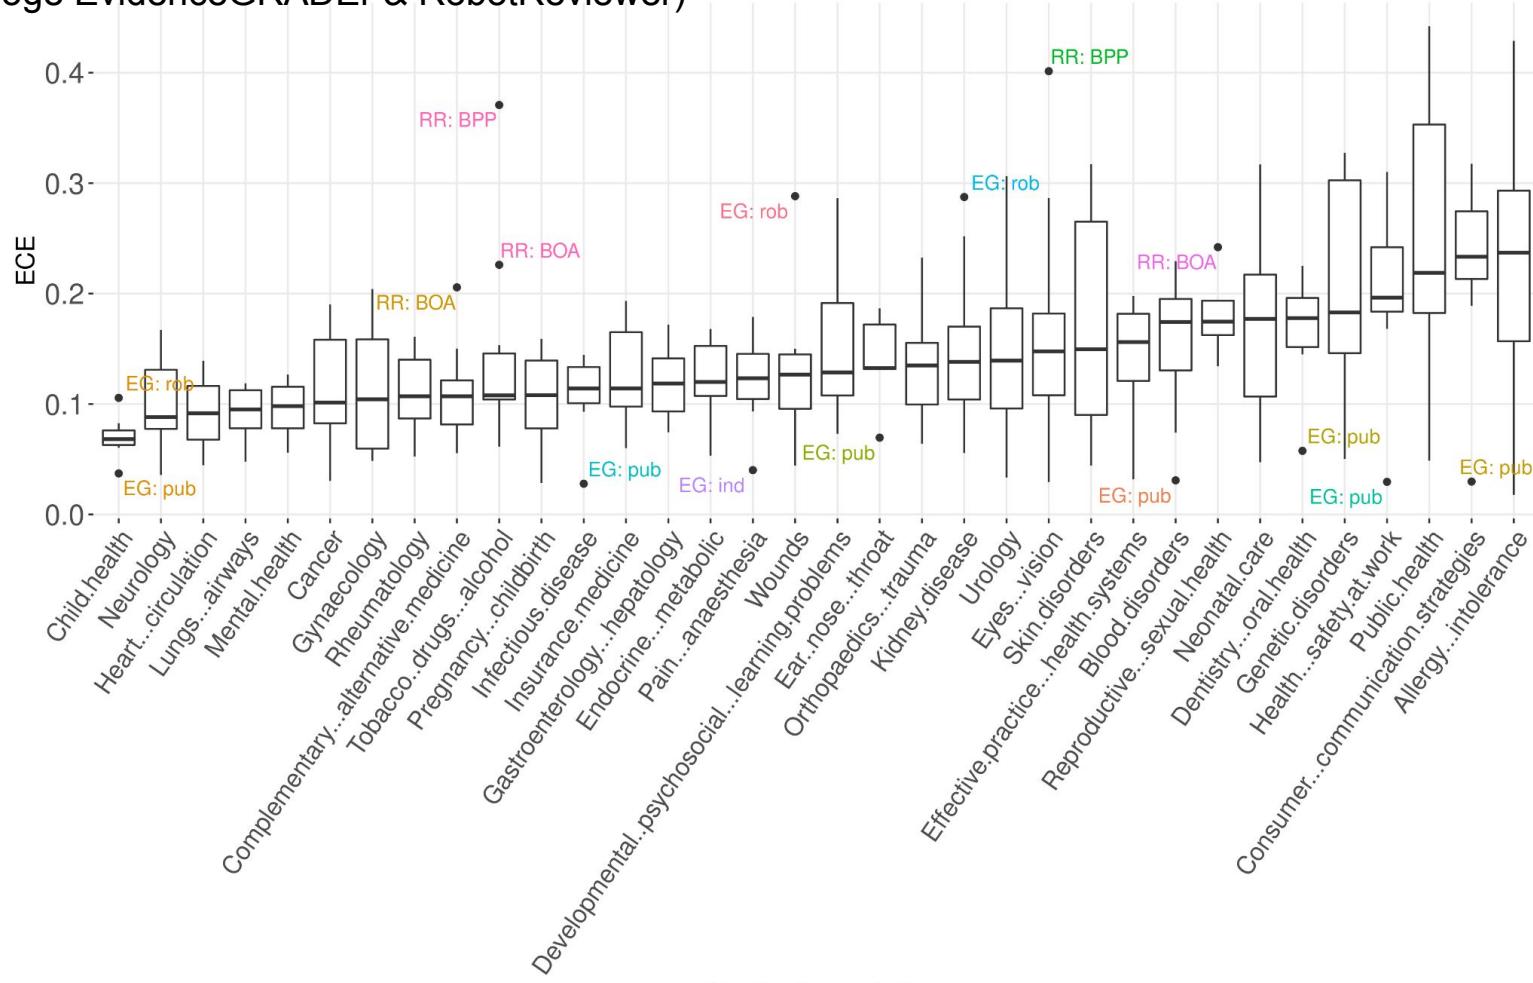
Neenakost v meri uspešnosti F1 po področjih

(vse naloge EvidenceGRADEr & RobotReviewer)



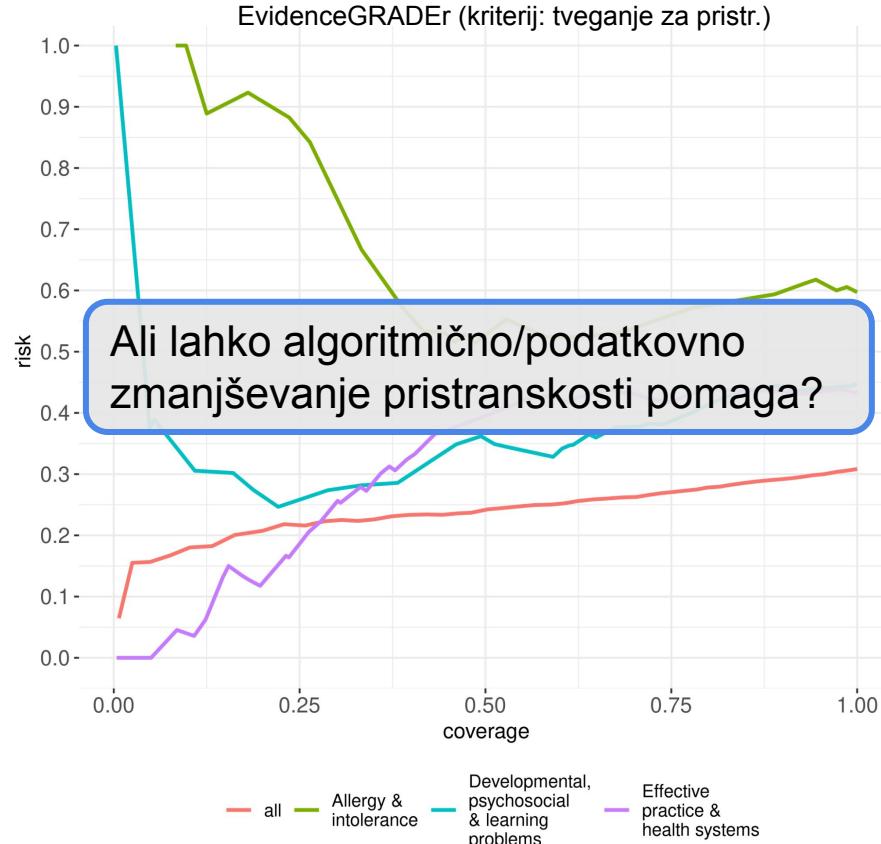
Neenakost v meri zanesljivosti ECE po področjih

(vse naloge EvidenceGRADEr & RobotReviewer)

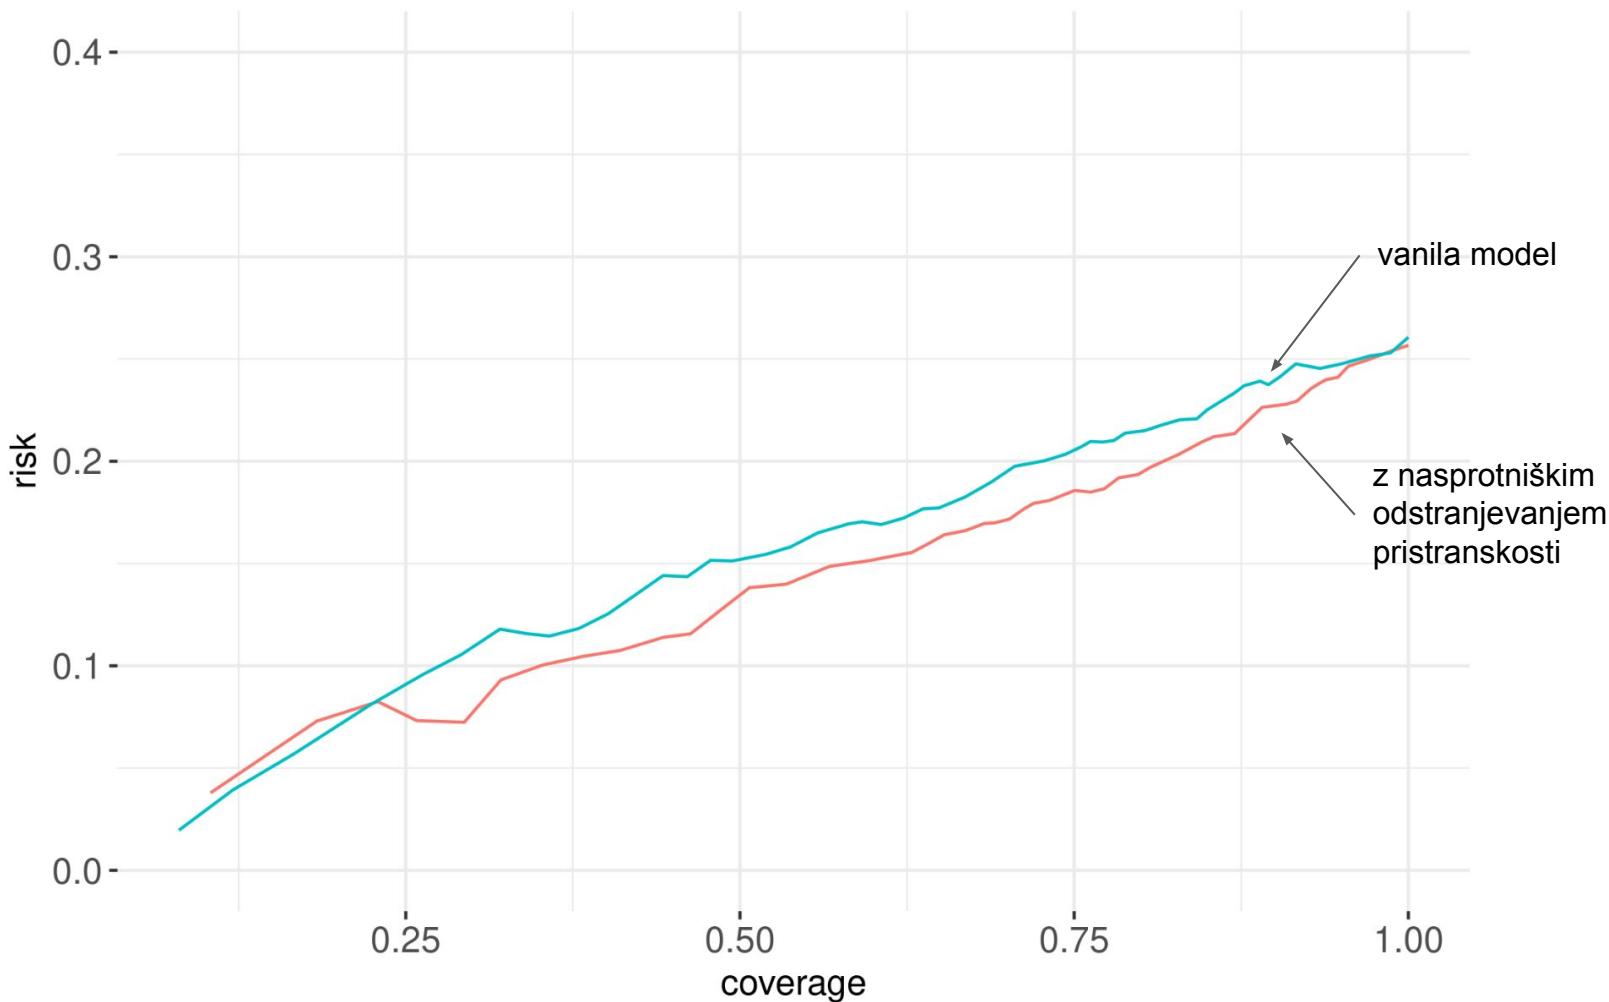


Izbirno napovedovanje (2/2)

povprečje proti trem področjem z najnižjo F1 pri polni pokritosti



binaryGRADE: Cancer



Poštenost (nepristranskost)

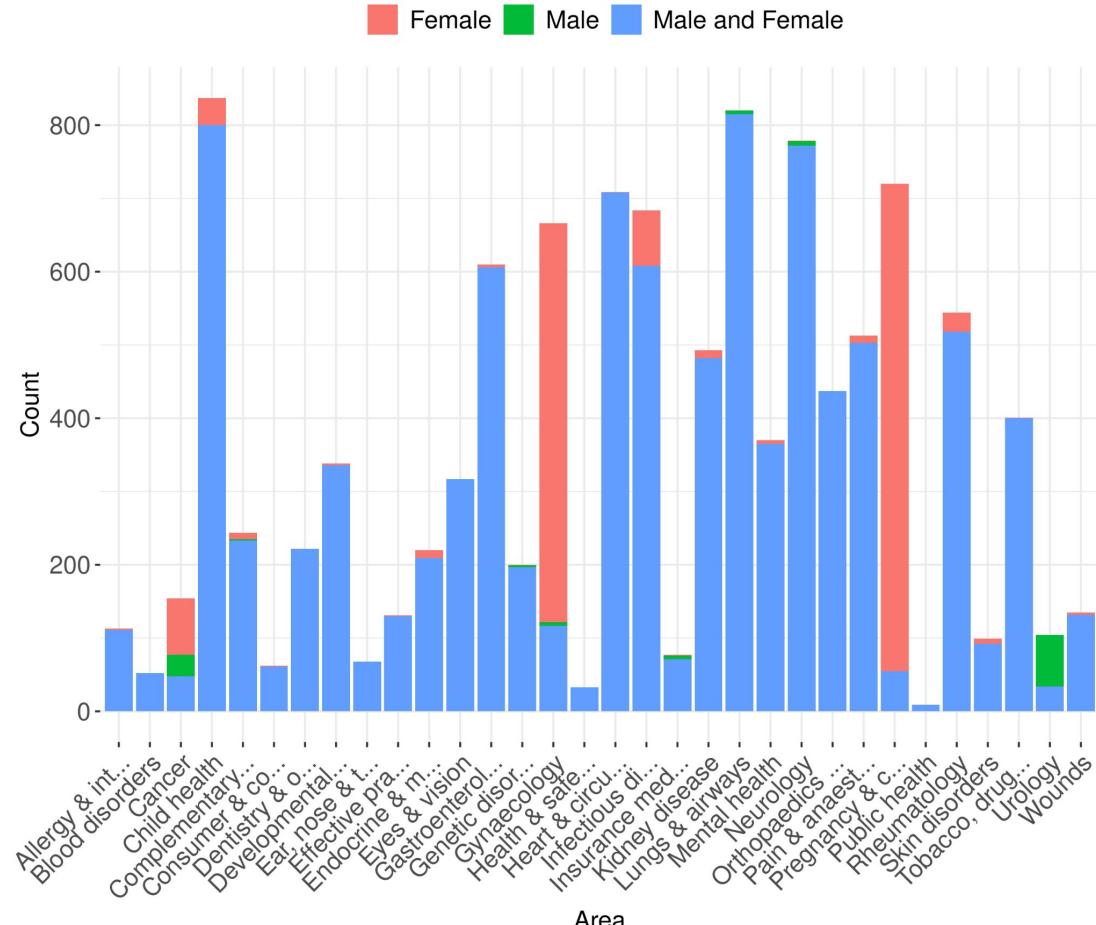
Poštenost glede na dva atributa:

- področje
- biološki spol

Vpliv na uspešnost:

- napovedovanja
- izbirne klasifikacije
- umerjenosti

Spodbujanje nepristrankosti po načelu enakih možnosti →
kompromisi med merami uspešnosti



Vloga v praksi

Polavtomatsko, kot podpora pri ročnem delu:

- dodaten "označevalec" (preverjanje skladnosti)
- glede na gotovost in uspešnost klasifikatorja bolj ali manj avtonomno delovanje

Omejen nabor vhodnih značilk v določenih fazah gradnje sist. pregleda

Kombiniranje z obstoječim sistemom RobotReviewer

Zaključek

- napovedovanje kakovosti izsledkov
- priprava podatkovne množice iz obstoječih virov
- rezultati odvisni od naloge (4- ali 2-točkovno, posamezni kriteriji)
- pomen izbirne klasifikacije in umerjenosti za praktično uporabo
- neuravnoteženost dokazov in spodbujanje nepristranskosti