

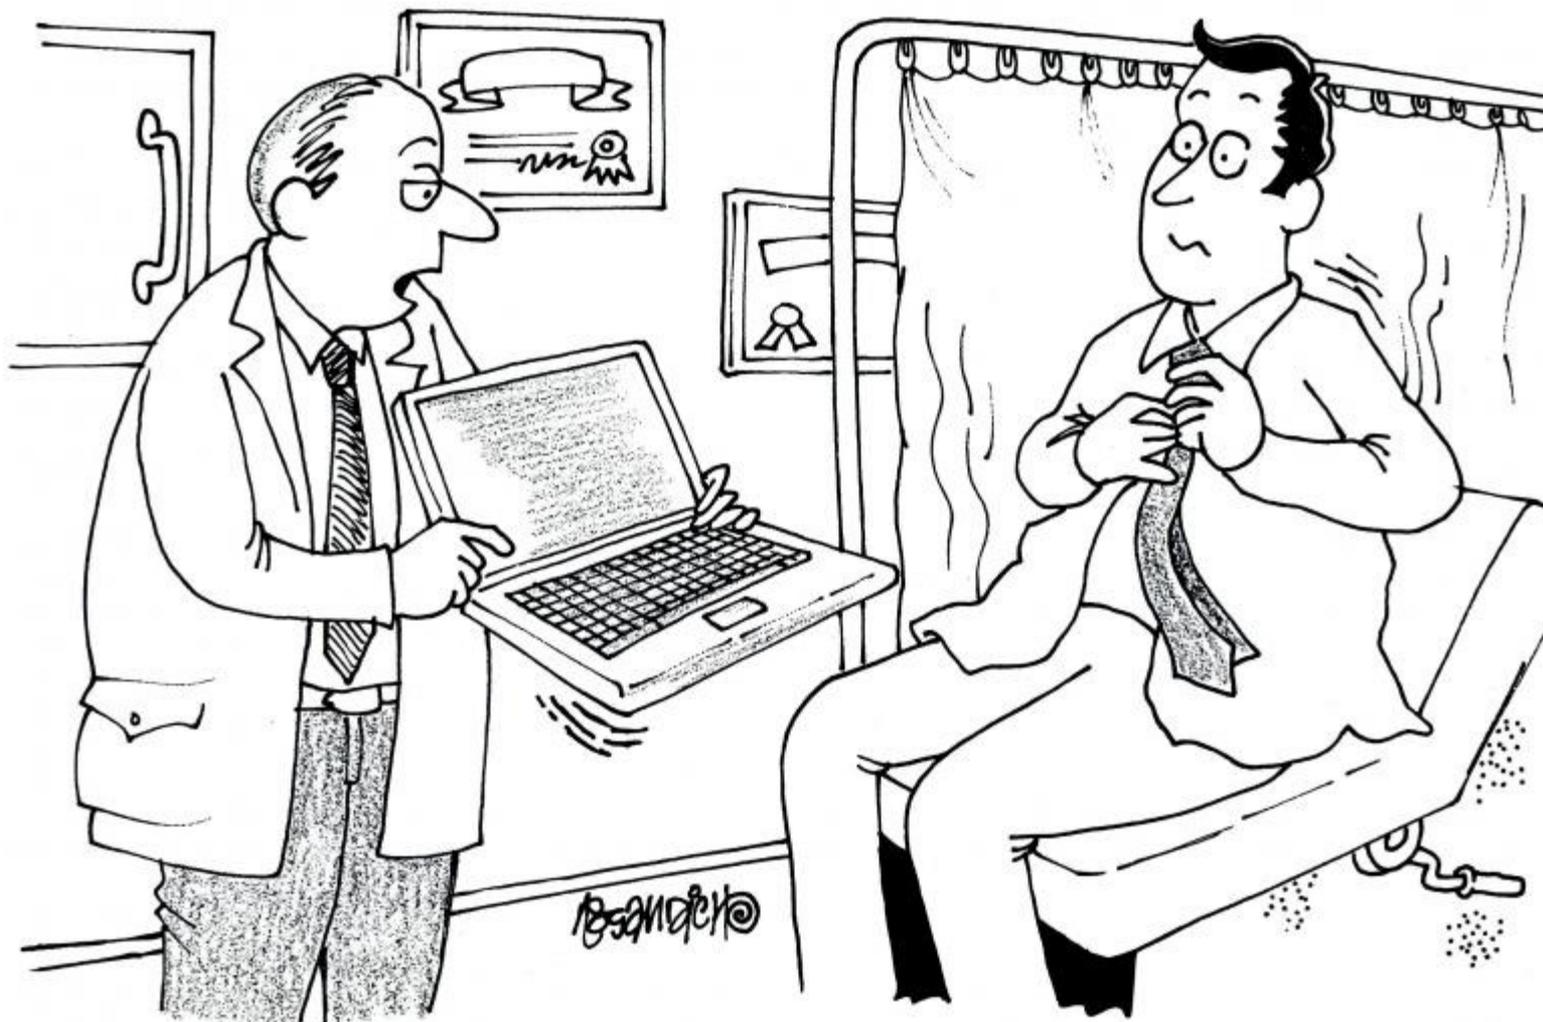
METODA UMETNE INTELIGENCE, KI ZNA PRISLUHNITI ZDRAVNIKOM

doc. dr. Matej Guid

Laboratorij za umetno inteligenco
Fakulteta za računalništvo in informatiko
Univerza v Ljubljani

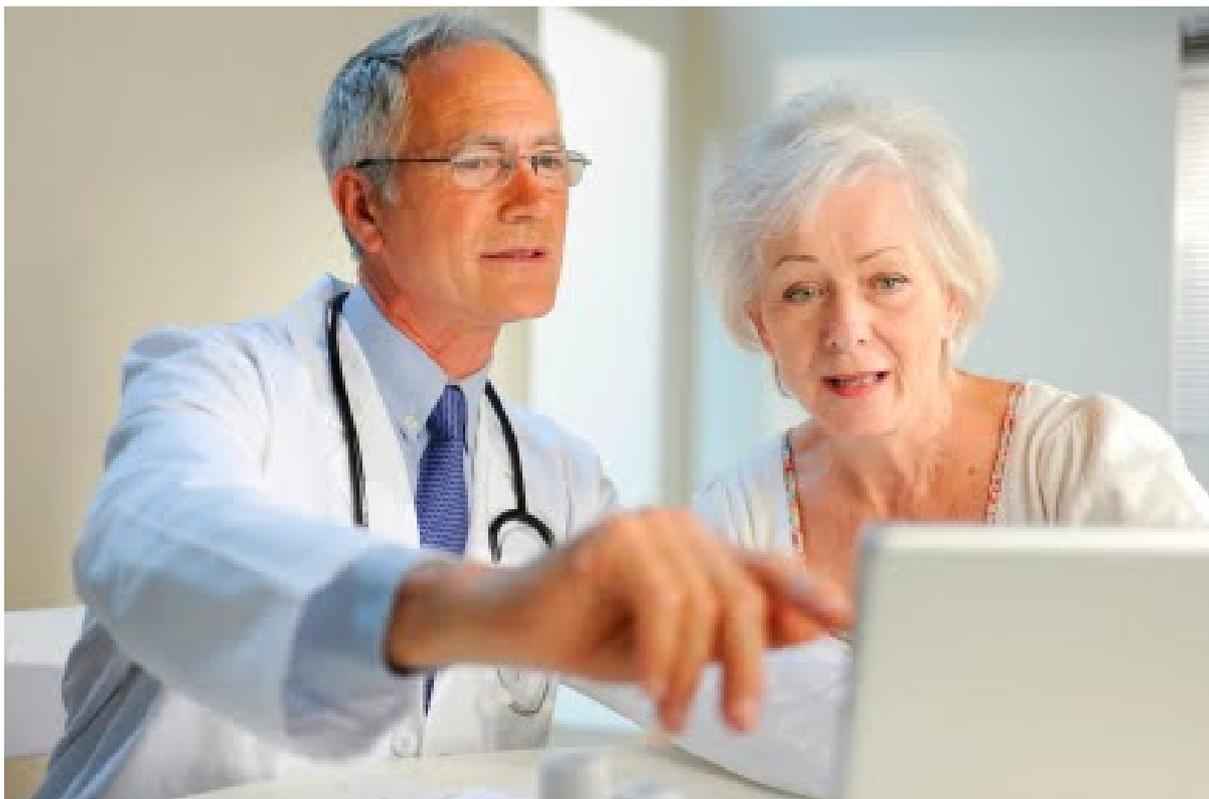


SINAPSIN NEVROZNAKSTVENI SEMINAR maj 2013

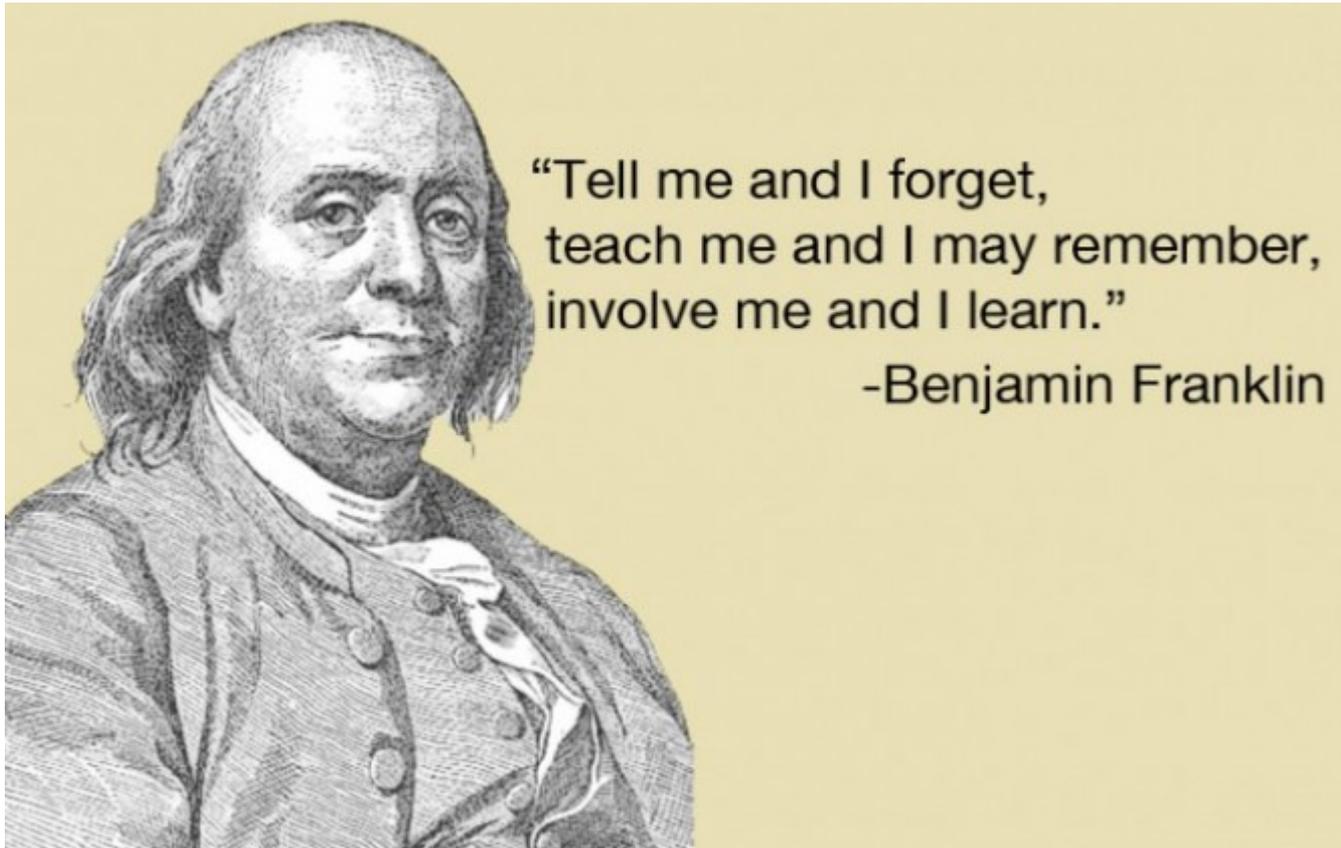


"If you want a second opinion, I'll ask my computer."

... POTREBUJEJO ZAUPANJE ZDRAVNIKOV!



VENDAR, KAKO PRIDOBITI ZAUPANJE ZDRAVNIKOV!?

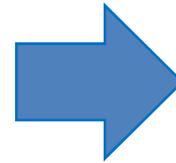
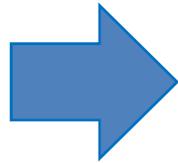


“Tell me and I forget,
teach me and I may remember,
involve me and I learn.”

-Benjamin Franklin

KAKO V PROCES UČENJA RAČUNALNIŠKIH MODELOV VPLESTI EKSPERTE?

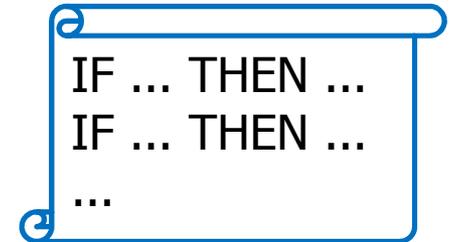
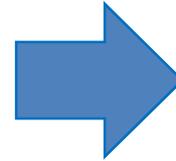
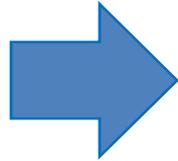
Ekspert lahko vnaprej poda omejitve in splošno znanje o domeni...



```
IF ... THEN ...  
IF ... THEN ...  
...
```

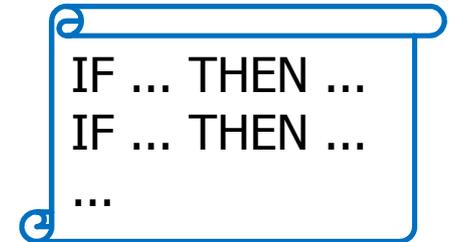
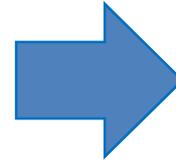
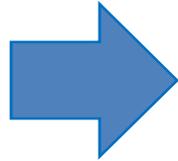
KAKO V PROCES UČENJA RAČUNALNIŠKIH MODELOV VPLESTI EKSPERTE?

... pregleda, ovrednoti in popravi rezultate strojnega učenja...



KAKO V PROCES UČENJA RAČUNALNIŠKIH MODELOV VPLESTI EKSPERTE?

... ali pa ekspert in računalnik v iterativnem postopku izboljšujeta model.



KAJ OD NAŠTETEGA SE VAM ZDI NAJBOLJE?



ALI

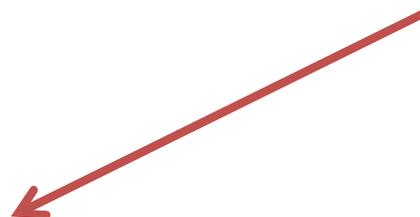
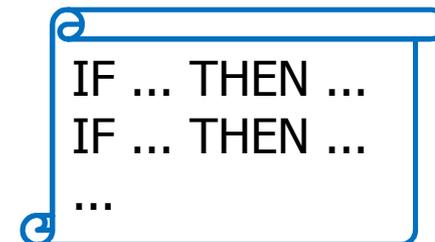


ALI



ZAKAJ NAM STROJNO UČENJE VČASIH POVZROČA PREGLAVICE?

Učni primeri
(podatki o pacientih)



Pravila lahko uspešno klasificirajo (diagnosticirajo), vendar:

- so pogosto težko razumljiva (tudi ekspertom)
- vodijo do nerazumljivih razlag

ILUSTRATIVNI PRIMER

Učenje diagnosticiranja gripe

Pacient	Temperatura	Cepljenje opravljeno	Kašljanje	Spol	Gripa
1	normalna	da	ne	ženska	ne
2	visoka	ne	da	moški	da
3	zelo visoka	ne	ne	moški	da
4	visoka	da	da	ženska	ne

Tipični program za učenje pravil bi se naučil naslednje pravilo:

IF Spol = moški THEN Gripa = da



To pravilo uspešno diagnosticira vse paciente v množici podatkov.

Vendar, razlaga npr. za Pacienta 3 se glasi: „**Ima gripo, ker je moški.**“ 😊

KAKO LAHKO EKSPERT POPRAVI NAPAKO?

Pacient	Temperatura	Cepljenje opravljeno	Kašljanje	Spol	Gripa
1	normalna	ne	ne	ženska	ne
2	visoka	ne	da	moški	da
3	zelo visoka	ne	ne	moški	da
4	visoka	da	da	ženska	ne

Možna razlaga za Pacienta 2:

„Pacient 2 je zbolel za gripo, ker ima visoko temperaturo.“



Prejšnje pravilo sedaj ni več konsistentno z ekspertovim **argumentom**.

KAJ PA, ČE JE EKSPERTOVA RAZLAGA NEPOPOLNA?

Pacient	Temperatura	Cepljenje opravljeno	Kašljanje	Spol	Gripa
1	normalna	ne	ne	ženska	ne
2	visoka	ne	da	moški	da
3	zelo visoka	ne	ne	moški	da
4	visoka	da	da	ženska	ne

Metoda strojnega učenja izpelje pravilo v skladu z argumentom:

IF Temperatura > Normal THEN Gripa = da



Vendar pa opazi nekonsistentnost s podatki in ekspertu poda **protiprimer**:

„Prosim primerjaj Pacienta 2 in 4, zakaj slednji nima gripe?“

EKSPERT IMA MOŽNOST DOPOLNITI SVOJE ARGUMENTE

Pacient	Temperatura	Cepljenje opravljeno	Kašljanje	Spol	Gripa
1	normalna	ne	ne	ženska	ne
2	visoka	ne	da	moški	da
3	zelo visoka	ne	ne	moški	da
4	visoka	da	da	ženska	ne

Ekspert poišče ključno razliko med Pacientoma 2 in 4:

„Pacient 2 ni opravil cepljenja proti gripi.“



EKSPERT IMA MOŽNOST DOPOLNITI SVOJE ARGUMENTE

Pacient	Temperatura	Cepljenje opravljeno	Kašljanje	Spol	Gripa
1	normalna	ne	ne	ženska	ne
2	visoka	ne	da	moški	da
3	zelo visoka	ne	ne	moški	da
4	visoka	da	da	ženska	ne

Metoda strojnega učenja se nauči novo pravilo:

IF Temperatura > Normal AND Cepljenje opravljeno = ne

THEN Gripa = da



Novo pravilo omogoča uspešno razlago tudi za Pacienta 3:

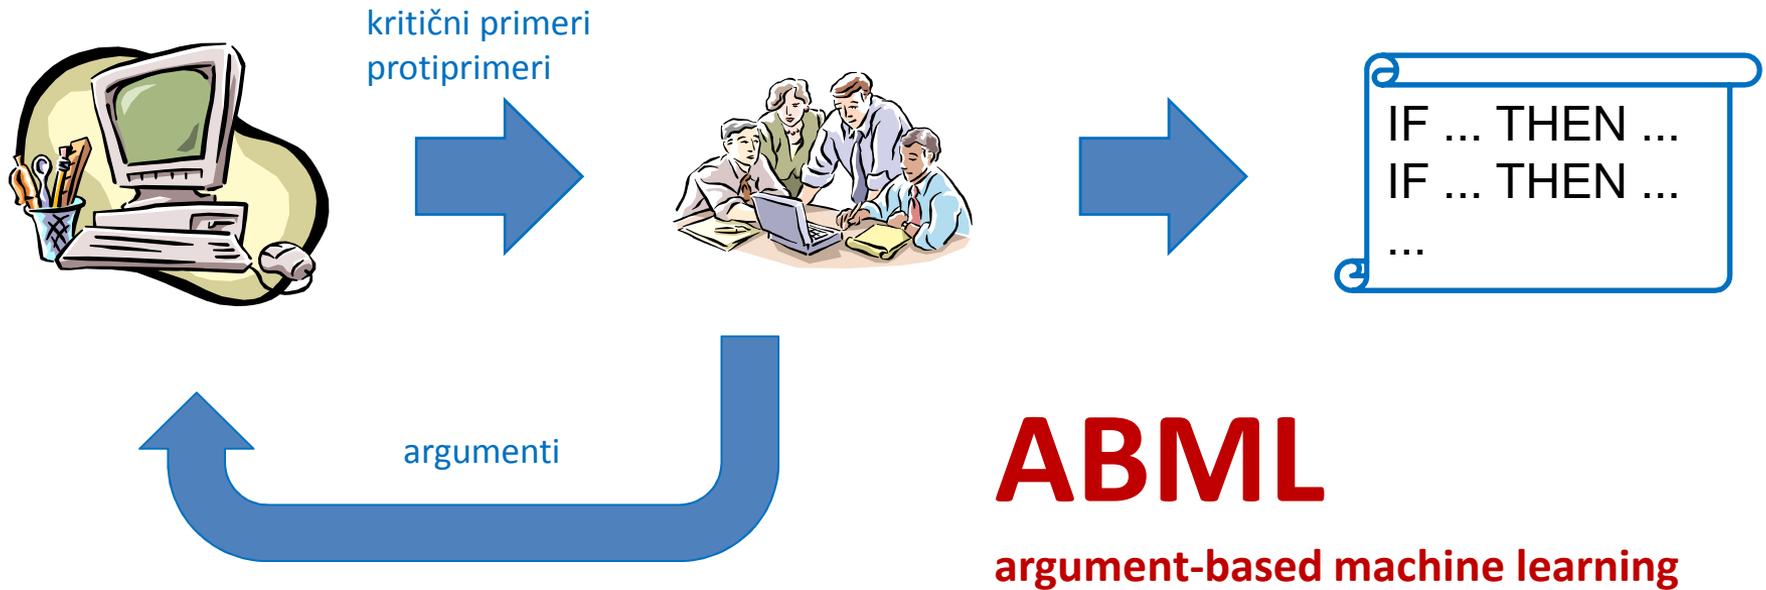
„Ima gripo, ker ima visoko temperaturo in ni opravil cepljenja proti gripi.“

KAJ SMO ILUSTRIRALI S TEM PRIMEROM?

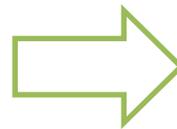
- Z razlago **enega** izbranega primera ekspert usmeri metodo strojnega učenja k izpeljavi pravil, ki so konsistentni z njegovim znanjem.
- Naučeno pravilo pokriva tudi ostale učne primere.
- Pravilo omogoča smiselno razlago postavljenih diagnoz.



ELICITACIJA ZNANJA Z ARGUMENTIRANIM STROJNIM UČENJEM (ABML)

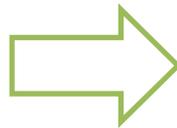


ekspertovi argumenti
usmerjajo učenje



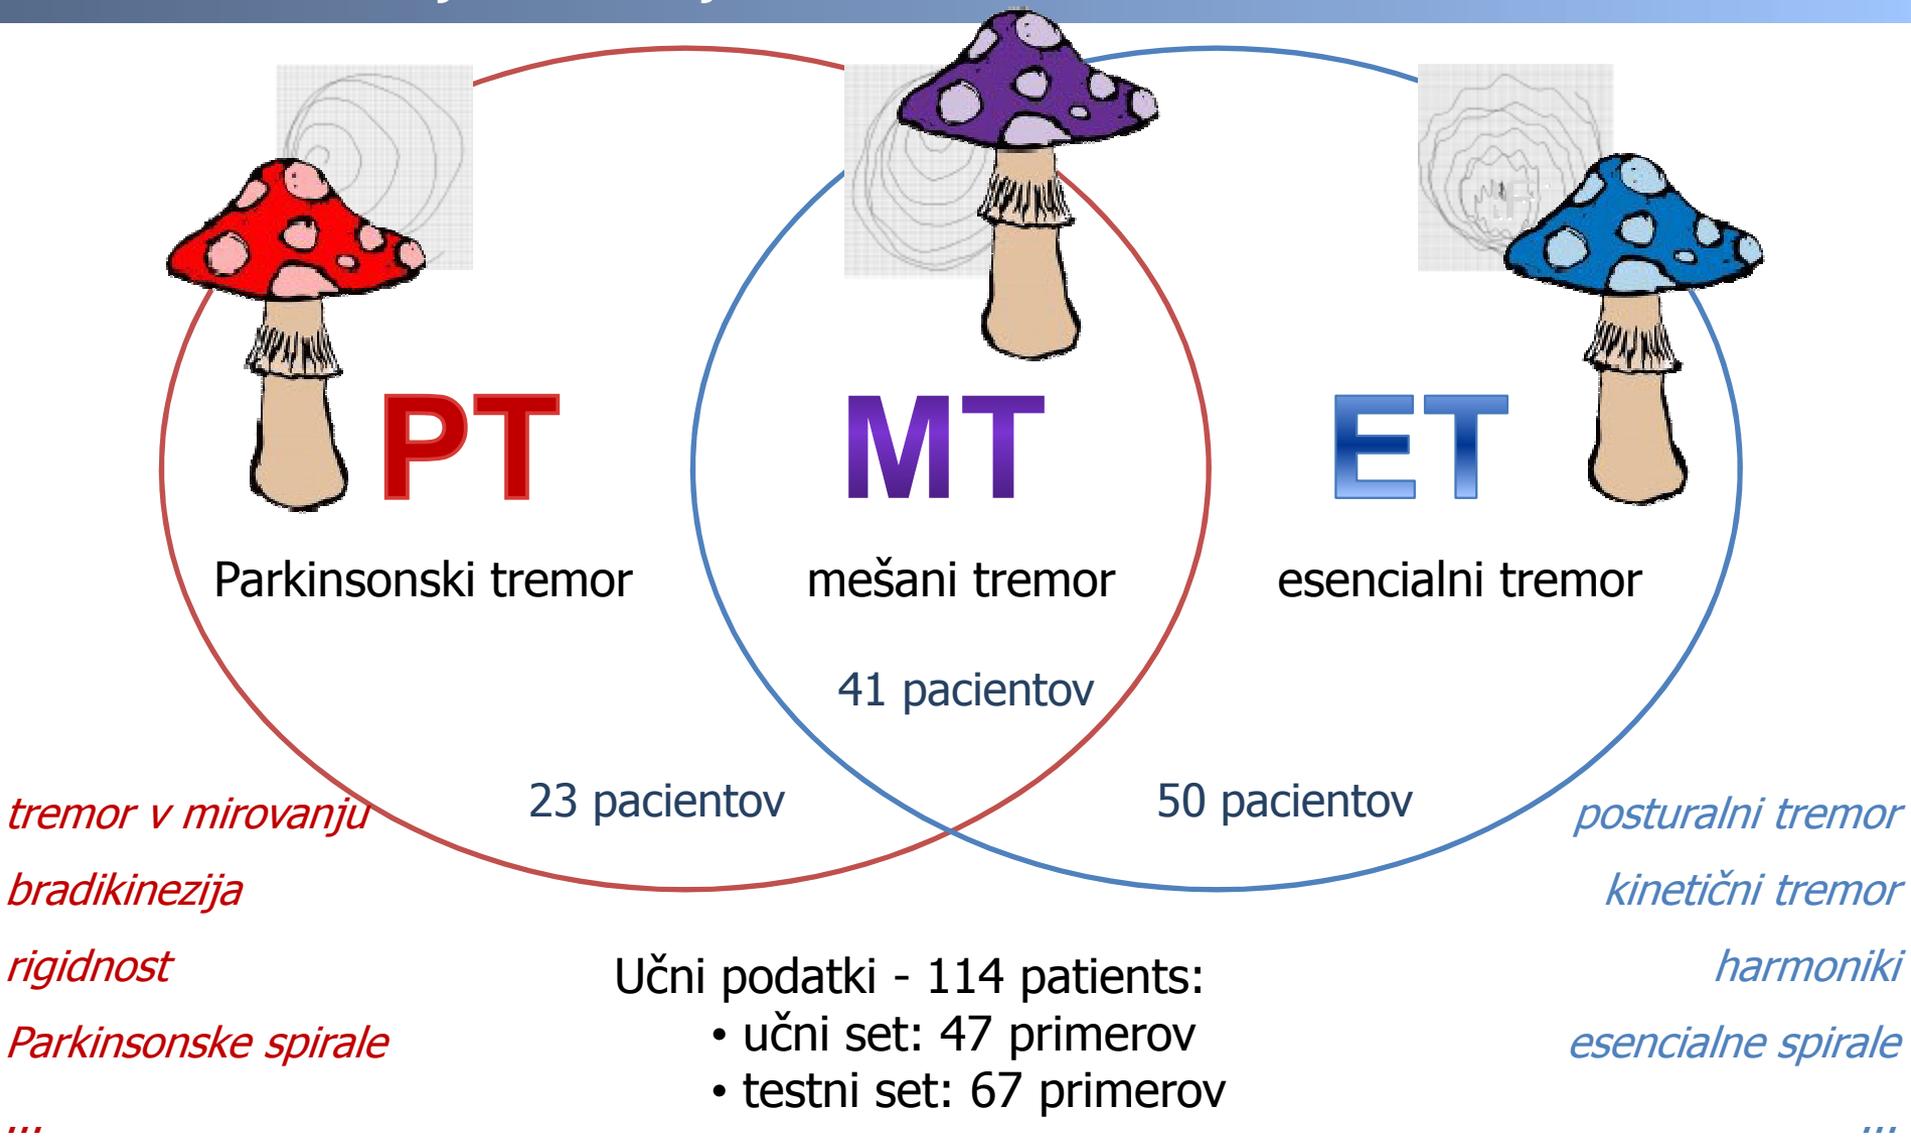
pridobljeni modeli so konsistentni
z ekspertnim znanjem

ekspert ima možnost
vpeljati nove koncepte



človeku razumljivi modeli

RAZLOČEVANJE TREMORJEV: OPIS UČNE DOMENE



Pacienti so bili na začetku opisani s **45 atributi**.

IF Rigidity.up.right ≤ 1
AND Resting.tremor.up.left ≤ 2
AND Postural.tremor.up.left > 0
AND Disease.duration < 9 years
THEN class = EMT

IF Bare.right.speed.time = Parkinsonian
AND Disease.duration < 12 years
THEN class = PMT

IF Rigidity.up.right > 0
AND Age ≤ 83 years
THEN class = PMT

IF Rigidity.up.right > 0
AND Disease.duration ≤ 12 years
THEN class = PMT

IF Bradykinesia.right > 0
AND Age ≤ 74 years
THEN class = PMT

**Ali bi zaupali
takšnim pravilom?**

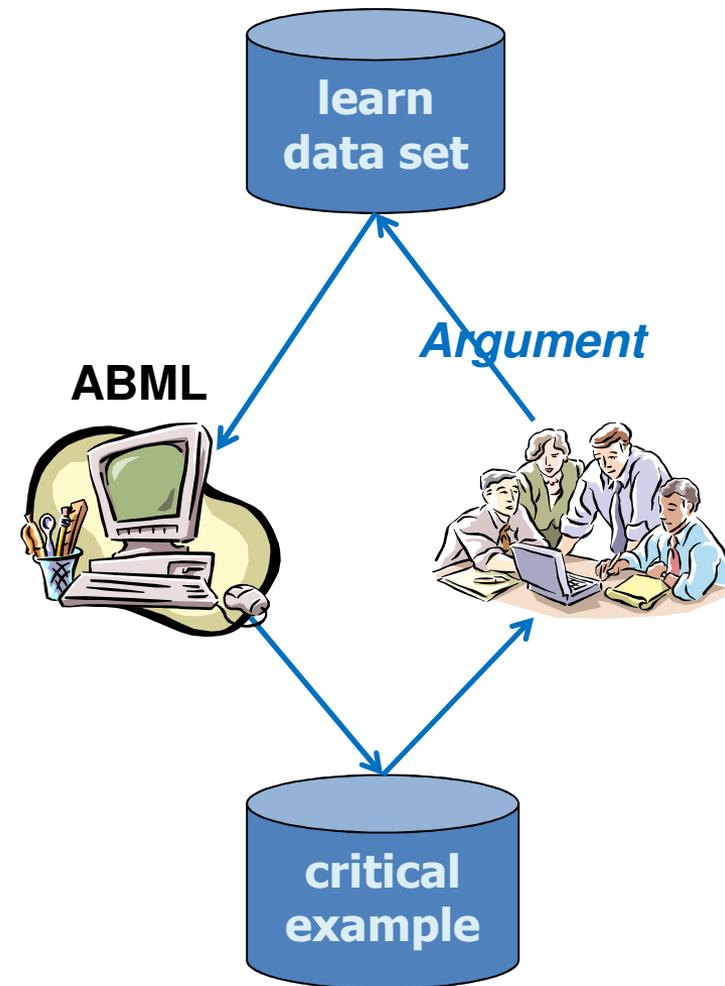
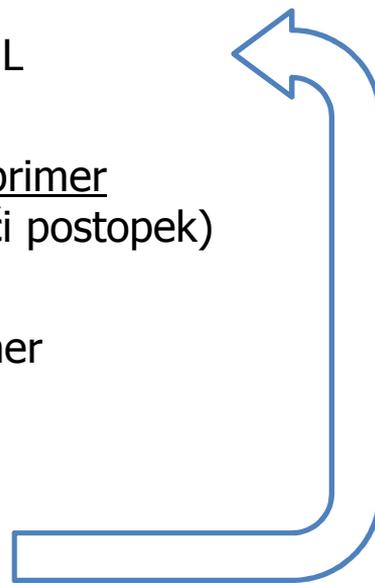
ABML: INTERAKCIJA MED STROJNIM UČENJEM IN EKSPERTOM

Korak 1: Nauči se hipoteze z ABML

Korak 2: Poišči "najbolj kritičen" primer
(če ga ne najdeš, zaključi postopek)

Korak 3: Ekspert razloži dani primer

Vrnitev h koraku 1



ABML: INTERAKCIJA MED STROJNIM UČENJEM IN EKSPERTOM

Korak 1: Nauči se hipoteze z ABML

Korak 2: Poišči "najbolj kritičen" primer
(če ga ne najdeš, zaključi postopek)

Korak 3: **Ekspert** razloži dani primer

Vrnitev h koraku 1

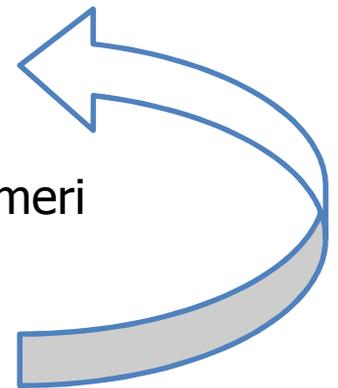
Korak 3a: Razlaga kritičnega primera (v naravnem jeziku)

Korak 3b: Dodajanje argumentov k primeru

Korak 3c: Odkrivanje **protiprimerov**

Korak 3d: Izboljševanje argumentov s protiprimeri

Vrnitev h koraku 3c, če je najden protiprimer



PRVI KRITIČNI PRIMER



E.65 MT → začetni model ni znal razložiti zakaj je ta primer klasificiran kot MT



Katere lastnosti govorijo v prid **ET** *in* katere lastnosti govorijo v prid **PT** ?



BRADYKINESIA.LEFT = 4
BRADYKINESIA.RIGHT = 4
KINETIC.TREMOR.UP.LEFT = 1
KINETIC.TREMOR.UP.RIGHT = 0
POSTURAL.TREMOR.UP.LEFT = 1
POSTURAL.TREMOR.UP.RIGHT = 0
QUALITATIVE.SPIRAL = ?
RESTING.TREMOR.UP.LEFT = 0
RESTING.TREMOR.UP.RIGHT = 0
RIGIDITY.UP.LEFT = 3
RIGIDITY.UP.RIGHT = 3
BARE.LEFT.FREQ.HARMONICS = NE
BARE.RIGHT.FREQ.HARMONICS = NE
TEMPLATE.LEFT.FREQ.HARMONICS = DA
TEMPLATE.RIGHT.FREQ.HARMONICS = NE
...

PRVI KRITIČNI PRIMER



E.65 MT → začetni model ni znal razložiti zakaj je ta primer klasificiran kot MT

Katere lastnosti govorijo v prid **ET**  in katere lastnosti govorijo v prid **PT**  ?

~~BRADYKINESIA.LEFT~~ = 4
~~BRADYKINESIA.RIGHT~~ = 4
KINETIC.TREMOR.UP.LEFT = 1
KINETIC.TREMOR.UP.RIGHT = 0
POSTURAL.TREMOR.UP.LEFT = 1
POSTURAL.TREMOR.UP.RIGHT = 0
QUALITATIVE.SPIRAL = ?
RESTING.TREMOR.UP.LEFT = 0
RESTING.TREMOR.UP.RIGHT = 0
RIGIDITY.UP.LEFT = 3
RIGIDITY.UP.RIGHT = 3
~~BARE.LEFT.FREQ.HARMONICS~~ = NE
~~BARE.RIGHT.FREQ.HARMONICS~~ = NE
~~TEMPLATE.LEFT.FREQ.HARMONICS~~ = DA
~~TEMPLATE.RIGHT.FREQ.HARMONICS~~ = NE

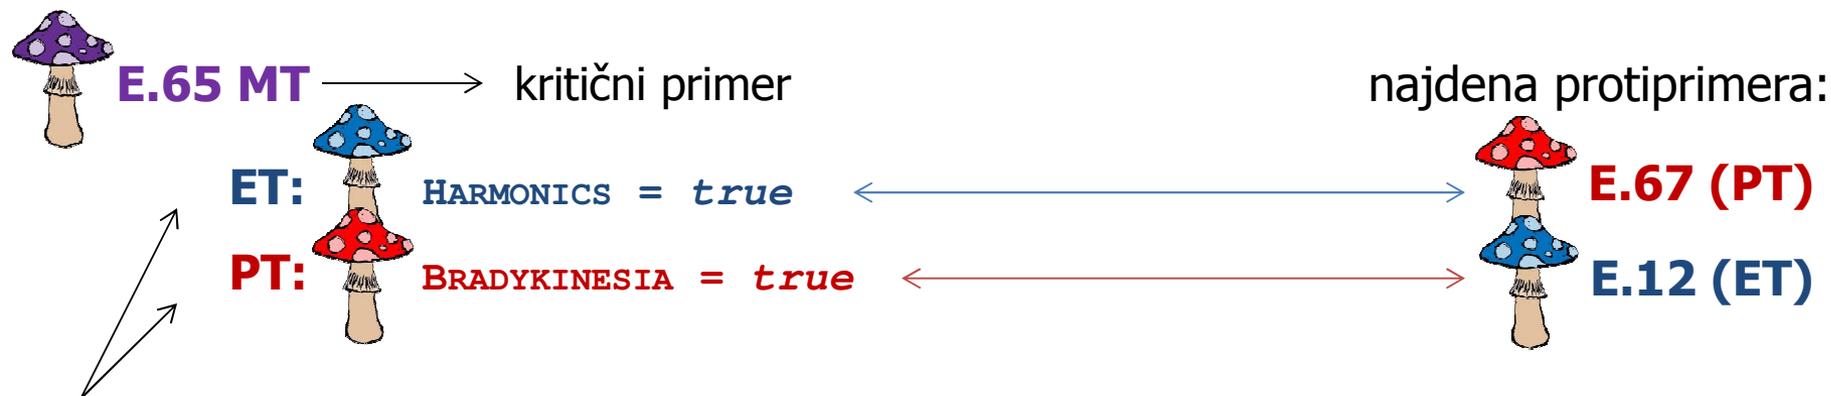
BRADYKINESIA = true



ekspert vpelje dva nova atributa

HARMONICS = true





argumenti se „pripnejo“ h kritičnemu primeru E.65

Katera je najpomembnejša lastnost v prid **ET** pri **E.65**, ki **ne velja** za **E.67**?



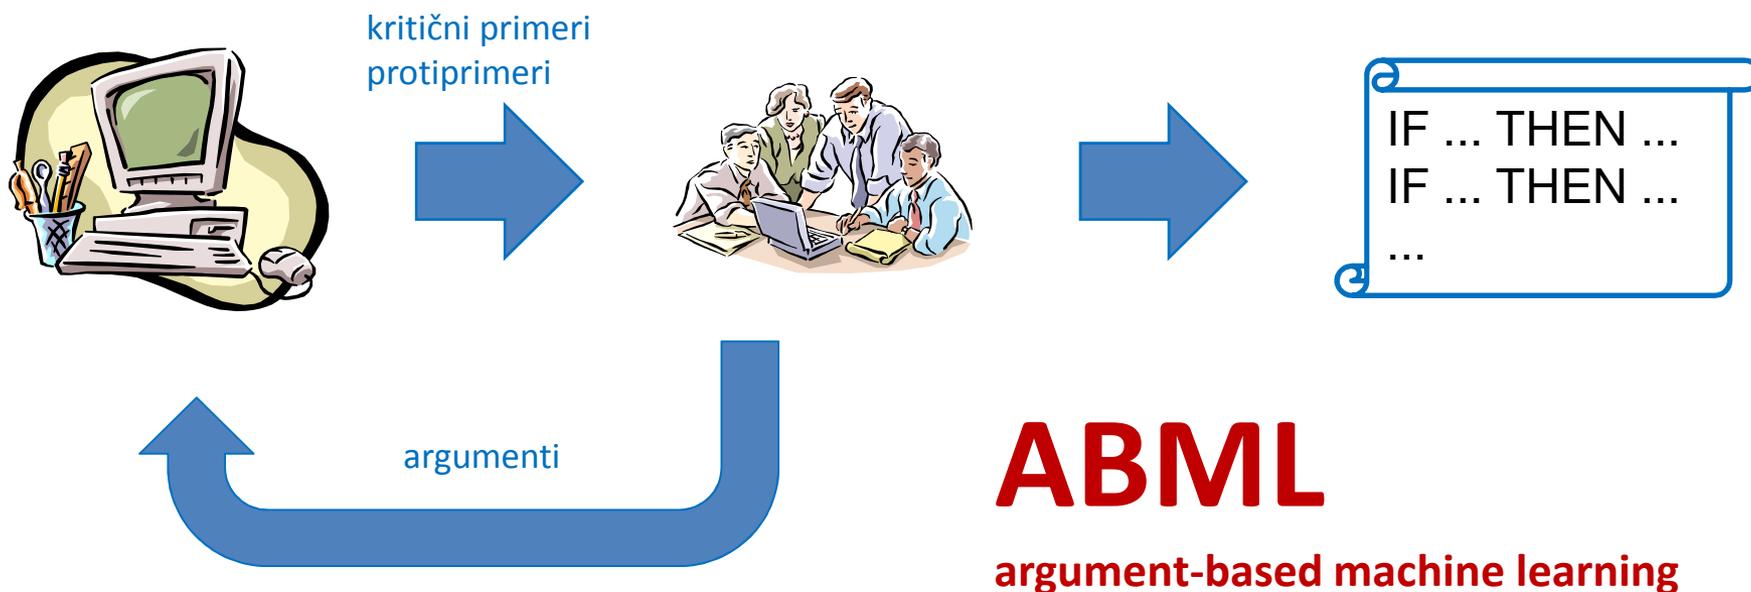
odgovor: napaka v podatkih – HARMONICS pri E.67 je bil spremenjen v *false*

Katera je najpomembnejša lastnost v prid **PT** pri **E.65**, ki **ne velja** za **E.12**?



odgovor: napačna diagnoza (!) – argumenti v prid PT pri E.12 so bili spregledani
E.12 se spremeni iz ET v MT

KAJ JE ILUSTRIRAL PREJŠNJI PRIMER?



Argumentirano strojno učenje lahko (med drugim) pomaga (tudi):

- odkriti morebitne napake v podatkih
- odkriti morebitne napake v postavljenih diagnozah
- usmerjati eksperta k iskanju bolj intuitivnih konceptov (atributov)



E.61 MT → model ni znal razložiti zakaj je ta primer klasificiran kot MT (in ne PT)

Katere lastnosti govorijo v prid **ET**?



```
BRADYKINESIA = false
KINETIC.TREMOR.UP.LEFT = 0
KINETIC.TREMOR.UP.RIGHT = 0
POSTURAL.TREMOR.UP.LEFT = 0
POSTURAL.TREMOR.UP.RIGHT = 3
QUALITATIVE.SPIRAL = Parkinsonian
RESTING.TREMOR.UP.LEFT = 0
RESTING.TREMOR.UP.RIGHT = 0
RIGIDITY.UP.LEFT = 0
RIGIDITY.UP.RIGHT = 1
HARMONICS = false
...
```



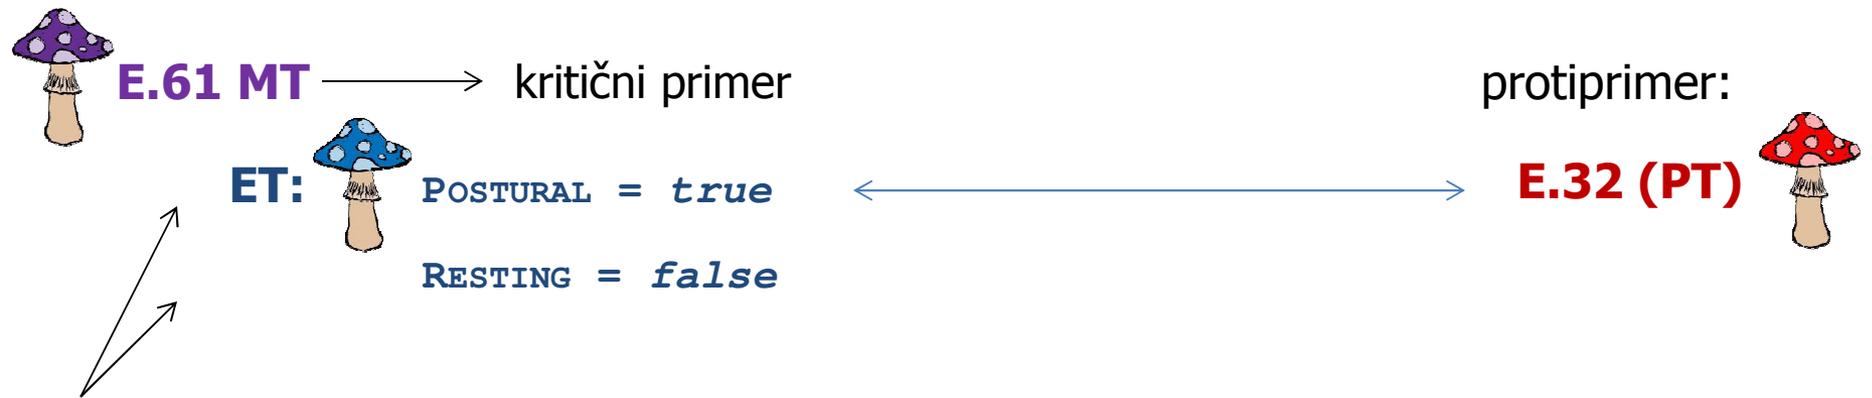
POSTURAL = true



RESTING = false



PROTIPRIMERI



argument „pripet“ h kritičnemu primeru E.61

Katera je najpomembnejša lastnost v prid **ET** pri **E.61**,
ki **ne velja** za **E.32**?  

odgovor: odsotnost lastnosti BRADYKINESIA pri E.61

Argument v prid ET pri **E.61**  je bil torej razširjen v:

`POSTURAL = true AND RESTING = false AND BRADYKINESIA = false`

ABML ZUNANJA ZANKA

Korak 1: Nauči se hipoteze z ABML

Korak 2: Poišči "najbolj kritičen" primer
(če ga ne najdeš, zaključi postopek)

Korak 3: Ekspert razloži dani primer

Vrnitev h koraku 1



ABML ZUNANJA ZANKA

Korak 1: Nauči se hipoteze z ABML

Korak 2: Poišči "najbolj kritičen" primer
(če ga ne najdeš, zaključi postopek)

Korak 3: **Ekspert** razloži dani primer

Vrnitev h koraku 1



ABML NOTRANJA ZANKA

Korak 3a: Razlaga „kritičnega“ primera (v naravnem jeziku)

“Prisotnost posturalnega tremorja in tremorja v mirovanju sta v prid ET...”

Korak 3b: Dodajanje argumentov k primeru

~~POSTURAL.TREMOR.UP.LEFT~~ = 0

~~POSTURAL.TREMOR.UP.RIGHT~~ = 3

} **POSTURAL = true**

~~RESTING.TREMOR.UP.LEFT~~ = 0

~~RESTING.TREMOR.UP.RIGHT~~ = 0

} **RESTING = false**



E.61 MT

→ kritični primer

ET:



POSTURAL = true

RESTING = false

Korak 3c: Odkrivanje **protiprimerov**

ET:



POSTURAL = true

RESTING = false



E.32 (PT)



Korak 3d: Izboljšanje argumentov s pomočjo protiprimerov

POSTURAL = true AND RESTING = false AND BRADYKINESIA = false

KONČNI MODEL

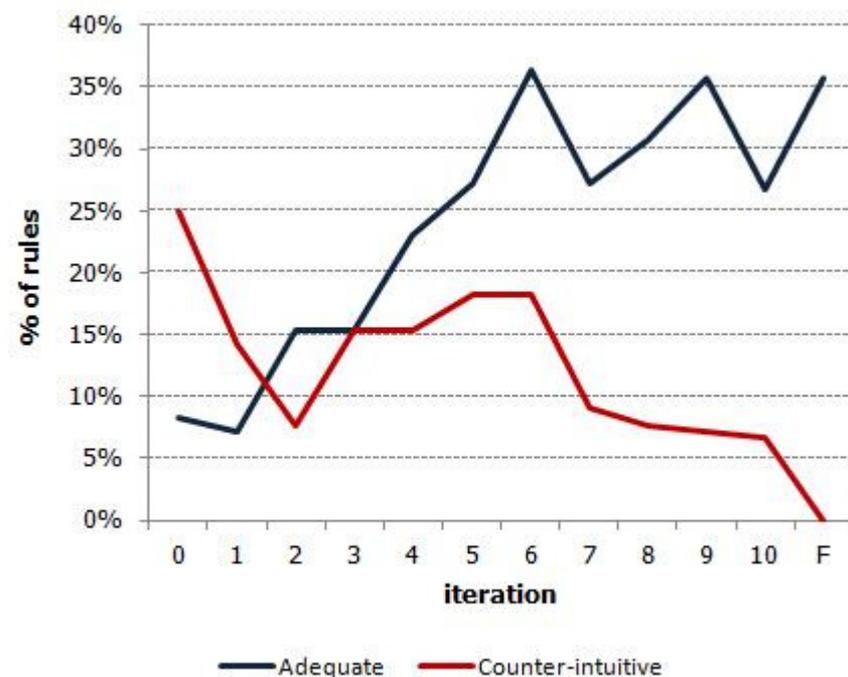
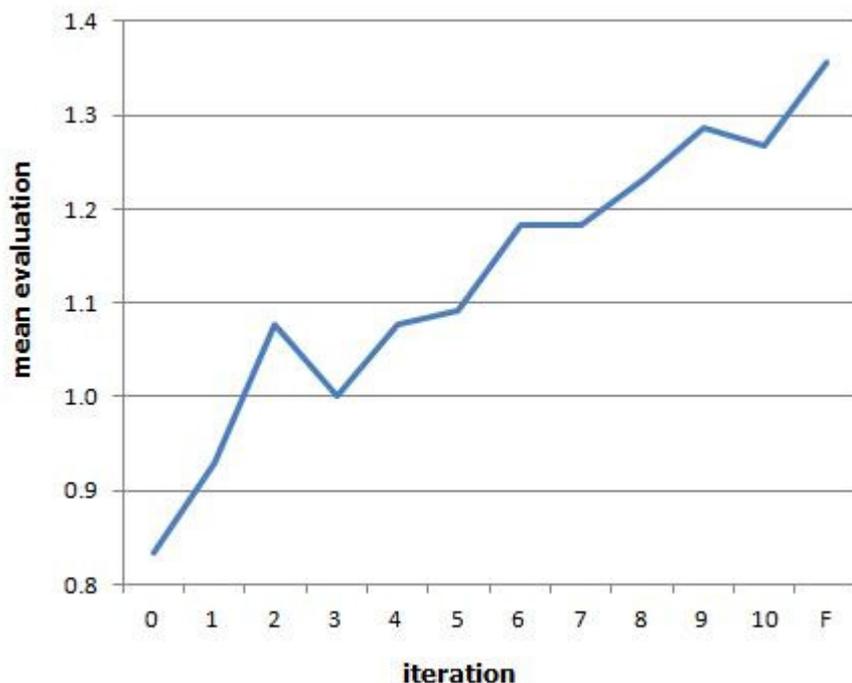
#	Condition	Class	+	-	E
1	IF QUALITATIVE.ASSESSMENT = <i>ET</i>	EMT	21	0	1
2	IF BRADYKINESIA = <i>false</i>	EMT	18	0	1
3	IF BRADYKINESIA = <i>true</i> AND RIGIDITY = <i>true</i>	PMT	17	0	2
4	IF QUALITATIVE.ASSESSMENT = <i>ET</i> AND POSTURAL = <i>true</i>	EMT	16	0	1
5	IF RIGIDITY = <i>false</i> AND KINETIC = <i>true</i>	EMT	15	0	1
6	IF KINETIC = <i>true</i> AND BRADYKINESIA = <i>false</i>	EMT	13	0	1
7	IF SPIRO.FREE.PT.ONLY = <i>true</i> AND SPIRO.TEMPLATE.ET.ONLY = <i>false</i>	PMT	13	0	1
8	IF HARMONICS = <i>true</i>	EMT	12	0	2
9	IF RESTING = <i>true</i> AND HARMONICS = <i>false</i> AND RIGIDITY = <i>true</i>	PMT	12	0	2
10	IF POSTURAL = <i>true</i> AND KINETIC = <i>true</i> AND RESTING = <i>false</i>	EMT	10	0	1
11	IF QUALITATIVE.ASSESSMENT = <i>PT</i>	PMT	10	0	1
12	IF RESTING = <i>false</i> AND POSTURAL = <i>true</i> AND BRADYKINESIA = <i>false</i>	EMT	8	0	2
13	IF POSTURAL = <i>true</i> AND ANAMNESIS = <i>positive</i> AND BRADYKINESIA = <i>false</i>	EMT	8	0	2
14	IF SPIRO.FREE.ET.ONLY = <i>true</i> AND SPIRO.TEMPLATE.ET.ONLY = <i>true</i>	EMT	7	0	1

čiste distribucije

Tekom procesa elicitacije ekspertnega znanja:

- **15 argumentov** je bilo podanih s strani eksperta
- **14 novih atributov** je bilo vključenih v domeno
- **21 atributov je bilo izključenih** iz domene

KONSISTENTNOST Z EKSPERTNIM ZNANJEM



Primerno	pravilo konsistentno z ekspertnim znanjem uporabno kot močan argument v prid ET ali PT	2
Smiselno	pravilo konsistentno z ekspertnim znanjem vendar ne zadostno za odločitev za ET ali PT brez dodatnih pravil	1
Neintuitivno	nelogično pravilo v kontradikciji z ekspertnim znanjem	0

KONČNI MODEL

#	Condition	Class	+	-	<i>E</i>
1	IF QUALITATIVE.ASSESSMENT = <i>ET</i>	E _{MT}	21	0	1
2	IF BRADYKINESIA = <i>false</i>	E _{MT}	18	0	1
3	IF BRADYKINESIA = <i>true</i> AND RIGIDITY = <i>true</i>	P _{MT}	17	0	2
4	IF QUALITATIVE.ASSESSMENT = <i>ET</i> AND POSTURAL = <i>true</i>	E _{MT}	16	0	1
5	IF RIGIDITY = <i>false</i> AND KINETIC = <i>true</i>	E _{MT}	15	0	1
6	IF KINETIC = <i>true</i> AND BRADYKINESIA = <i>false</i>	E _{MT}	13	0	1
7	IF SPIRO.FREE.PT.ONLY = <i>true</i> AND SPIRO.TEMPLATE.ET.ONLY = <i>false</i>	P _{MT}	13	0	1
8	IF HARMONICS = <i>true</i>	E _{MT}	12	0	2
9	IF RESTING = <i>true</i> AND HARMONICS = <i>false</i> AND RIGIDITY = <i>true</i>	P _{MT}	12	0	2
10	IF POSTURAL = <i>true</i> AND KINETIC = <i>true</i> AND RESTING = <i>false</i>	E _{MT}	10	0	1
11	IF QUALITATIVE.ASSESSMENT = <i>PT</i>	P _{MT}	10	0	1
12	IF RESTING = <i>false</i> AND POSTURAL = <i>true</i> AND BRADYKINESIA = <i>false</i>	E _{MT}	8	0	2
13	IF POSTURAL = <i>true</i> AND ANAMNESIS = <i>positive</i> AND BRADYKINESIA = <i>false</i>	E _{MT}	8	0	2
14	IF SPIRO.FREE.ET.ONLY = <i>true</i> AND SPIRO.TEMPLATE.ET.ONLY = <i>true</i>	E _{MT}	7	0	1

brez nelogičnih pravil

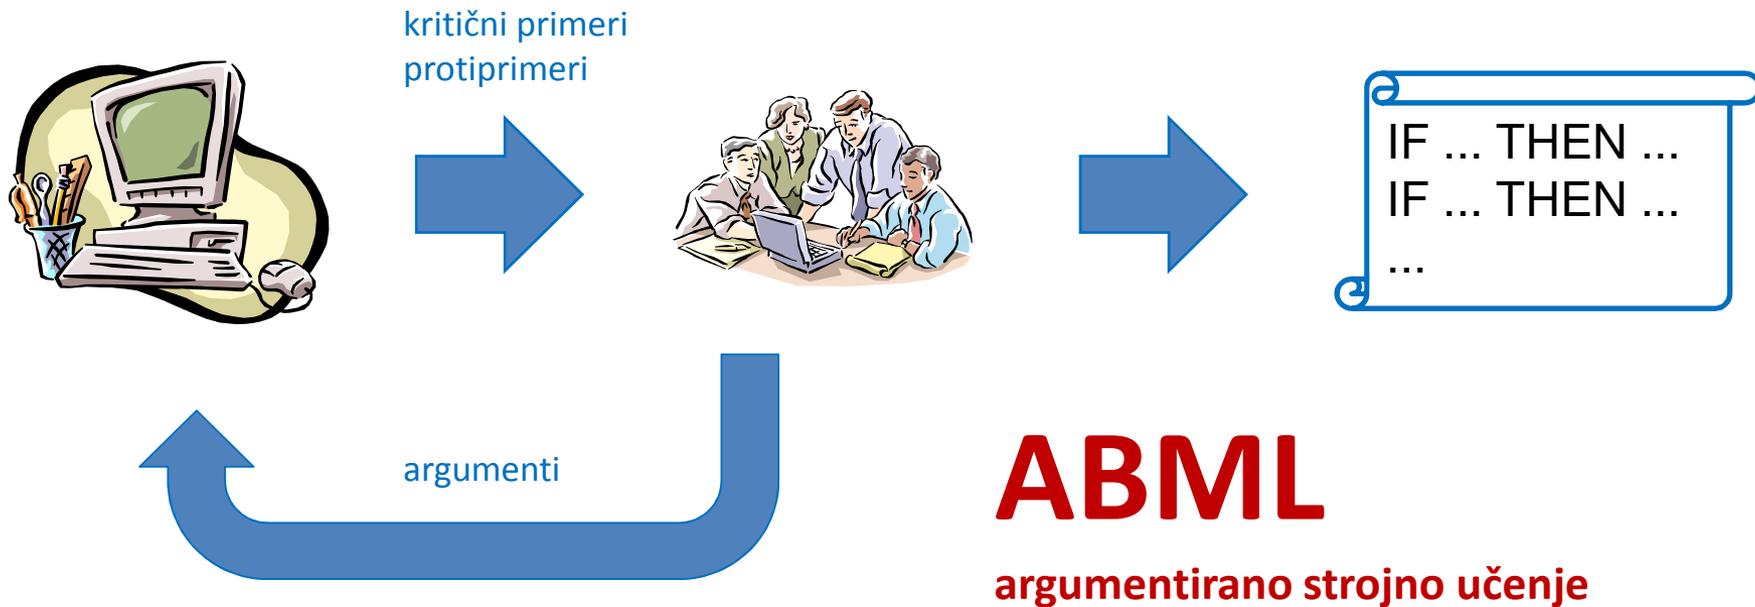
čiste distribucije

klasifikacijske točnosti na testnih podatkih:

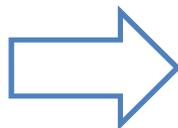
Metoda	Začetni model	Končni Model
Naivni Bayes	63%	74%
kNN	58%	81%
učenje pravil (ABCN2)	52%	82%

Točnosti vseh metod so se **izboljšale z novimi atributi**, ki jih je dodal domenski ekspert.

ELICITACIJA ZNANJA Z ARGUMENTIRANIM STROJNIM UČENJEM

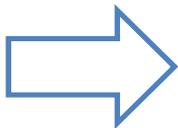


razlaga le enega
primeru hkrati



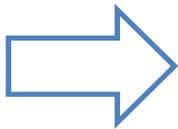
ekspertu je lažje izraziti svoje znanje

“kritični” primeri



ekspert podaja le najbolj relevantno znanje

protiprimeri



detektiranje pomanjkljivosti v razlagah

ALI BODO ZDRAVNIKI (KONČNO) LAHKO BOLJ ZAUPALI RAČUNALNIKOM?





Prosojnice so na voljo na:

<http://www.ailab.si/matej/>

Matej Guid

matej.guid@fri.uni-lj.si
+386 (0)41 395 824



[Faculty of computer and information science](#)
University of Ljubljana
Trzaska 25, 1000 Ljubljana
Slovenia

