


Mesterséges Intelligencia MI

Logikai ágens
cselekvésben -
szituációkalkulustól
tervkészítésig

Dobrowiecki Tadeusz
Eredics Péter, és mások





BME I.E. 437, 463-28-99

dobrowiecki@mit.bme.hu,

<http://www.mit.bme.hu/general/staff/tade>



A festő ágens problémája



Predikátum kalkulus hogyan vethető be a környezetüket alakító intelligens rendszerek leírására? Meg kell oldani annak ábrázolását, hogy az idő múlik, az ágens cselekszik, és ennek hatására változik az ágens környezete. Az ágens világában egy asztal és egy szék van. Ágens bútort kizárólag pirosra tud festeni. Egyik bútor sem piros, de csak az asztalt szeretnénk pirosnak.

Hogyan írjuk le logikával, hogy milyen világgal szembesül az ágens, és milyen világot hagy maga után? Ráadásul legyen ez a leírás kellően általános is.

A festő ágens problémája



\neg piros(Asztal)



piros(Asztal)

volt?

lesz?

Ellentmondás!

A festő ágens problémája



¬ piros(Asztal)



piros(Asztal)

¬ piros(Asztal,S1)

piros(Asztal,S2)

Már nincs
ellentmondás!

A festő ágens problémája



¬ piros(Asztal)

piros(Asztal)

¬ piros(Asztal, S1)

piros(Asztal, S2)

S1



S2

objektum

objektum

Hogyan kapcsoljuk össze?

A festő ágens problémája



\neg piros(Asztal)

piros(Asztal)

\neg piros(Asztal, S1)

piros(Asztal, S2)

S1

S2



objektum

objektum

S2 = eredmény(Átfest, S1)

Hogyan kapcsoljuk össze?

A festő ágens problémája




kék(Szék)

kék(Szék)



volt

lesz?



Nincs ellentmondás!

A festő ágens problémája



kék(Szék)


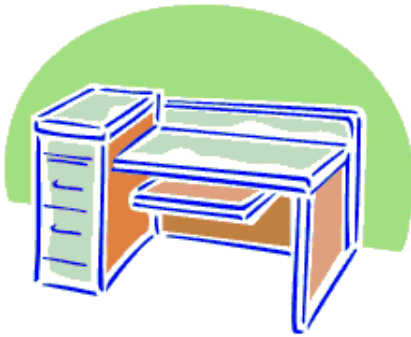
kék(Szék)

kék(Szék,S1)

kék(Szék,S2)

De van helyette probléma!

A festő ágens problémája



kék(Szék)

kék(Szék)

kék(Szék, S1)

kék(Szék, S2)

S1

S2

objektum

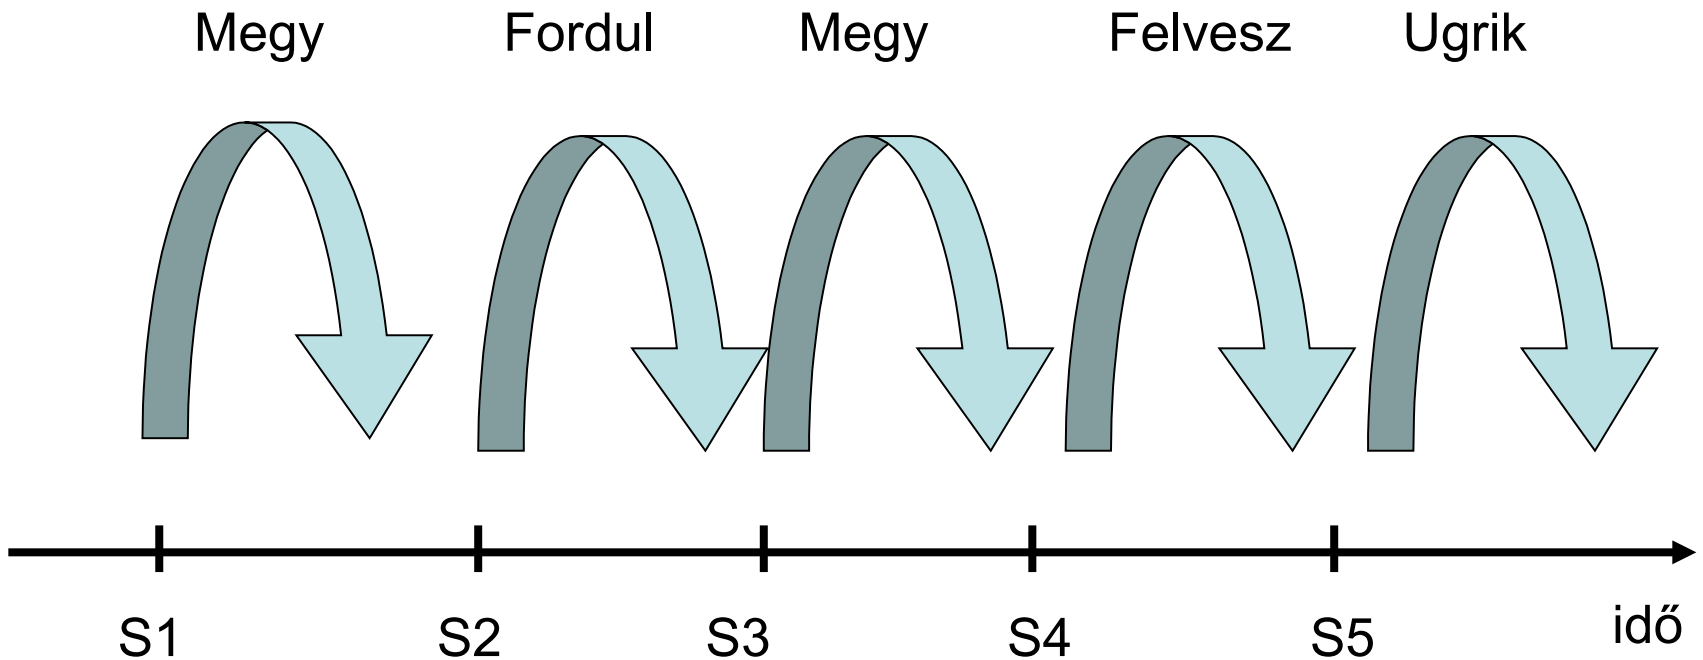
objektum

S2 = eredmény(Átfest, S1)

Hogyan kapcsoljuk össze?

Szituáció kalkulus

- a változások leírásának egy módja az elsőrendű logikában.
 - a világ a **szituációk** sorozatából áll
 - mindegyike egy „pillanat felvétel” a világ állapotáról
 - egy-egy szituációban egy tény igaz, vagy hamis, **változhat!**
- fluent** = „folyékony esemény” (pl. piros(Szék, σ))



Hatás axiómák (Wumpus probléma esetére)

Pl. az arany nyomon követése: állítani kell bármely szituációban, hogy ha az arany ott van-e, és az ágens **Megfogta**, akkor az adódó szituációban (és majd később is) birtokolni fogja az aranyat:

$$\forall s \text{ ott}(\text{Arany},s) \wedge \text{vihető}(\text{Arany}) \rightarrow \mathbf{birtokol}(\text{Arany},\text{eredmény}(\text{Megfogás},s))$$

Hasonlóan az ágens nem birtokol semmit az **Elenged** cselekvése után:

$$\forall x, s \neg \mathbf{birtokol}(x, \text{eredmény}(\text{Elenged}, s))$$

Sajnos ez nem elég! Szükség van még

Keret axiómák

Hogyha az ágens birtokol valamit és nem engedi el, akkor a következő szituációban is fogja birtokolni. Ha az ágens nem birtokol valamit és nem tudja megfogni, akkor a következő állapotban sem fogja birtokolni:

$$\forall a, x, s \mathbf{birtokol}(x, s) \wedge (a \neq \text{Elenged}) \rightarrow \mathbf{birtokol}(x, \text{eredmény}(a, s))$$

$$\forall a, x, s \neg \mathbf{birtokol}(x, s) \wedge (a \neq \text{Megfogás} \vee \neg (\text{ott}(x, s) \wedge \text{vihető}(x))) \\ \rightarrow \neg \mathbf{birtokol}(x, \text{eredmény}(a, s))$$

Egy elegánsabb reprezentáció:

hatás axióma és keret axióma egyetlen axiómába:

**Igaz utána \Leftrightarrow [bármely cselekvés, amely igazá tette
 \vee már igaz volt és nem volt olyan cselekvés,
ami hamissá tette volna]**

A *Birtokol* esetében az utód-állapot axióma a következő:

$\forall a, x, s$ **birtokol** (x,eredmény (a, s)) \Leftrightarrow
[(a = Megfogás \wedge ott (x,s) \wedge vihető(x)) \vee (**birtokol** (x,s) \wedge a \neq Elenged)]

A világ rejtett tulajdonságainak a levezetése

Ok-okozati szabályok:

a világ ok-okozatiságának feltételezett iránya:

a világ rejtett tulajdonságai okozzák bizonyos érzetek keletkezését.

$\forall I1, I2, s \text{ hely}(Wumpus, I1, s) \wedge \text{szomszédos}(I1, I2) \rightarrow \text{büdös}(I2)$

$\forall I1, I2, s \text{ hely}(Csapda, I1, s) \wedge \text{szomszédos}(I1, I2) \rightarrow \text{szellős}(I2)$

(modell-alapú következtető rendszer) (“méret” független)

Diagnosztikai szabályok:

rejtett tulajdonságok meglétére következtetnek, közvetlenül az érzetből származó információk felhasználásával **(abdukció kikerülése, antikauzális)**.

$\forall I1, s \text{ бүдös}(I1) \rightarrow (\exists I2 \text{ hely}(Wumpus, I2, s) \wedge (I2 = I1 \vee \text{szomszédos}(I1, I2))$

Egy cél-orientált ágens

Ha az ágens aranyat megtalálta, a cselekvési stratégiát radikálisan meg kell változtatnia.

Az új cél most az, hogy kimeneküljön olyan gyorsan, amilyen gyorsan csak lehet. Most azt kellene kikövetkeztetni, hogy az ágens **célja** az [1,1] pozíció:

$$\forall s \text{ birtokol}(\text{Arany}, s) \rightarrow \text{célpozíció}([1,1], s)$$

Egy explicit cél jelenléte lehetővé teszi az ágens számára, hogy elkészítsen egy cselekvések sorozatából álló mondatot (tervet), amellyel elérheti a célt (és hajtja is végre – ezt a viselkedést kell rendszer specifikációban megadni és így implementálni).

Legalább három módja van egy ilyen mondat megtalálásának:

Kereséssel már láttuk

Következtetéssel lássuk!

Lenne más is ... ?

Tervkészítés következtetéssel szituációkalkulusban

Legyen a feladat nyelvezete:

Ágens szobában van, S szituációban: $szoba(\text{Ágens}, S)$
asztal színe piros, S szituációban: $piros(\text{Asztal}, S)$

Mivel más objektum nincs is, le lehet rövidíteni:

ágens szobában van, S (kezdeti) szituációban: $szoba(S)$
asztal színe piros, S (kezdeti) szituációban: $piros(S)$

Ágens cselekvései legyenek: **“Bemegy”**, **“Kimegy”**, **“Átfest”**.

Jelen helyzet: 1. $\neg szoba(S)$
2. $\neg piros(S)$

azaz az ágens szobán kívül van, szobában az asztal nincs pirosra átfestve.

Probléma: a kívánt helyzet az, hogy az asztal piros legyen és az ágens szobán kívül legyen. Az ágens képes ezt megvalósítani?

Létezik egyáltalán egy ilyen helyzet?

Hatás axiómák (avagy az ágens kényszercselekedetei)

$$\forall \sigma. \neg \text{szoba}(\sigma) \wedge \neg \text{piros}(\sigma) \rightarrow \text{szoba}(\text{eredmény}(\text{Bemegy}, \sigma))$$

$$\forall \sigma. \text{szoba}(\sigma) \wedge \neg \text{piros}(\sigma) \rightarrow \text{piros}(\text{eredmény}(\text{Atfest}, \sigma))$$

$$\forall \sigma. \text{szoba}(\sigma) \wedge \text{piros}(\sigma) \rightarrow \neg \text{szoba}(\text{eredmény}(\text{Kimegy}, \sigma))$$

$$\forall \sigma. \text{szoba}(\sigma) \rightarrow \neg \text{szoba}(\text{eredmény}(\text{Kimegy}, \sigma))$$

$$\forall \sigma. \neg \text{szoba}(\sigma) \rightarrow \text{szoba}(\text{eredmény}(\text{Bemegy}, \sigma))$$

$$\forall \sigma. \neg \text{piros}(\sigma) \rightarrow \text{piros}(\text{eredmény}(\text{Atfest}, \sigma))$$

Mitől lesz ilyen? Ha ilyenek megtervezzük és implementáljuk

Keret axiómák (buta formában)

$$\forall \sigma. \text{szoba}(\sigma) \rightarrow \text{szoba}(\text{eredmény}(\text{Atfest}, \sigma))$$

$$\forall \sigma. \text{piros}(\sigma) \rightarrow \text{piros}(\text{eredmény}(\text{Bemegy}, \sigma))$$

$$\forall \sigma. \text{piros}(\sigma) \rightarrow \text{piros}(\text{eredmény}(\text{Kimegy}, \sigma))$$

$$\forall \sigma. \neg \text{piros}(\sigma) \rightarrow \neg \text{piros}(\text{eredmény}(\text{Kimegy}, \sigma))$$

$$\forall \sigma. \neg \text{piros}(\sigma) \rightarrow \neg \text{piros}(\text{eredmény}(\text{Bemegy}, \sigma))$$

...

Probléma: a kívánt helyzet az, **létezik egyáltalán?**

$$\exists \sigma. \neg \text{szoba}(\sigma) \wedge \text{piros}(\sigma) ?$$

Legyen egy további rövidítés: $B(s) = \text{eredmény}(\text{Bemegy}, s)$
 $K(s) = \text{eredmény}(\text{Kimegy}, s)$
 $A(s) = \text{eredmény}(\text{Átfest}, s)$

Ne felejtjük, hogy a beszédes logikai nevek nem a gépnek szólnak, hanem az embereknek, és a gépi eljárásra nincsenek hatással.

Átírással klóz formára:

1. $\neg \text{szoba}(S)$
2. $\neg \text{piros}(S)$
3. $\text{szoba}(\sigma 1) \vee \text{piros}(\sigma 1) \vee \text{szoba}(B(\sigma 1))$
4. $\neg \text{szoba}(\sigma 2) \vee \text{piros}(\sigma 2) \vee \text{piros}(A(\sigma 2))$
5. $\neg \text{szoba}(\sigma 3) \vee \neg \text{piros}(\sigma 3) \vee \neg \text{szoba}(K(\sigma 3))$
6. $\neg \text{szoba}(\sigma 4) \vee \text{szoba}(A(\sigma 4))$
7. $\neg \text{szoba}(\sigma 5) \vee \neg \text{szoba}(K(\sigma 5))$
8. $\text{szoba}(\sigma 6) \vee \text{szoba}(B(\sigma 6))$
9. $\neg \text{piros}(\sigma 7) \vee \text{piros}(B(\sigma 7))$
10. $\neg \text{piros}(\sigma 8) \vee \text{piros}(K(\sigma 8))$
11. $\text{piros}(\sigma 9) \vee \neg \text{piros}(K(\sigma 9))$
12. $\text{piros}(\sigma 10) \vee \neg \text{piros}(B(\sigma 10))$
13. $\text{piros}(\sigma 11) \vee \text{piros}(A(\sigma 11))$
14. $\text{szoba}(\sigma 12) \vee \neg \text{piros}(\sigma 12)$

és még egy egyszerűsítés (diszjunkció explicite nem szükséges):

1. $\neg \text{sz}(S)$
2. $\neg p(S)$
3. $\text{sz}(\sigma 1) \quad p(\sigma 1) \quad \text{sz}(B(\sigma 1))$
4. $\neg \text{sz}(\sigma 2) \quad p(\sigma 2) \quad p(A(\sigma 2))$
5. $\neg \text{sz}(\sigma 3) \quad \neg p(\sigma 3) \quad \neg \text{sz}(K(\sigma 3))$
6. $\neg \text{sz}(\sigma 4) \quad \text{sz}(A(\sigma 4))$
7. $\neg \text{sz}(\sigma 5) \quad \neg \text{sz}(K(\sigma 5))$
8. $\text{sz}(\sigma 6) \quad \text{sz}(B(\sigma 6))$
9. $\neg p(\sigma 7) \quad p(B(\sigma 7))$
10. $\neg p(\sigma 8) \quad p(K(\sigma 8))$
11. $p(\sigma 9) \quad \neg p(K(\sigma 9))$
12. $p(\sigma 10) \quad \neg p(B(\sigma 10))$
13. $p(\sigma 11) \quad p(A(\sigma 11))$
14. $\text{sz}(\sigma 12) \quad \neg p(\sigma 12)$

1. $\neg sz(S)$
2. $\neg p(S)$
3. $sz(\sigma1) \quad p(\sigma1) \quad sz(B(\sigma1))$
4. $\neg sz(\sigma2) \quad p(\sigma2) \quad p(A(\sigma2))$
5. $\neg sz(\sigma3) \quad \neg p(\sigma3) \quad \neg sz(K(\sigma3))$
6. $\neg sz(\sigma4) \quad sz(A(\sigma4))$
7. $\neg sz(\sigma5) \quad \neg sz(K(\sigma5))$
8. $sz(\sigma6) \quad sz(B(\sigma6))$
9. $\neg p(\sigma7) \quad p(B(\sigma7))$
10. $\neg p(\sigma8) \quad p(K(\sigma8))$
11. $p(\sigma9) \quad \neg p(K(\sigma9))$
12. $p(\sigma10) \quad \neg p(B(\sigma10))$
13. $p(\sigma11) \quad p(A(\sigma11))$
14. $sz(\sigma12) \quad \neg p(\sigma12)$

2. és 12. -ből

15. $\neg p(B(S)) \quad \sigma10/S$

1. $\neg \text{sz}(S)$
2. $\neg p(S)$
3. $\text{sz}(\sigma 1) \quad p(\sigma 1) \quad \text{sz}(B(\sigma 1))$
4. $\neg \text{sz}(\sigma 2) \quad p(\sigma 2) \quad p(A(\sigma 2))$
5. $\neg \text{sz}(\sigma 3) \quad \neg p(\sigma 3) \quad \neg \text{sz}(K(\sigma 3))$
6. $\neg \text{sz}(\sigma 4) \quad \text{sz}(A(\sigma 4))$
7. $\neg \text{sz}(\sigma 5) \quad \neg \text{sz}(K(\sigma 5))$
8. $\text{sz}(\sigma 6) \quad \text{sz}(B(\sigma 6))$
9. $\neg p(\sigma 7) \quad p(B(\sigma 7))$
10. $\neg p(\sigma 8) \quad p(K(\sigma 8))$
11. $p(\sigma 9) \quad \neg p(K(\sigma 9))$
12. $p(\sigma 10) \quad \neg p(B(\sigma 10))$
13. $p(\sigma 11) \quad p(A(\sigma 11))$
14. $\text{sz}(\sigma 12) \quad \neg p(\sigma 12)$
15. $\neg p(B(S))$

1., 2, és 3. -ből

16. $\text{sz}(B(S)) \quad \sigma 1/S$

3. $sz(\sigma1) \quad p(\sigma1) \quad sz(B(\sigma1))$
4. $\neg sz(\sigma2) \quad p(\sigma2) \quad p(A(\sigma2))$
5. $\neg sz(\sigma3) \quad \neg p(\sigma3) \quad \neg sz(K(\sigma3))$
6. $\neg sz(\sigma4) \quad sz(A(\sigma4))$
7. $\neg sz(\sigma5) \quad \neg sz(K(\sigma5))$
8. $sz(\sigma6) \quad sz(B(\sigma6))$
9. $\neg p(\sigma7) \quad p(B(\sigma7))$
10. $\neg p(\sigma8) \quad p(K(\sigma8))$
11. $p(\sigma9) \quad \neg p(K(\sigma9))$
12. $p(\sigma10) \quad \neg p(B(\sigma10))$
13. $p(\sigma11) \quad p(A(\sigma11))$
14. $sz(\sigma12) \quad \neg p(\sigma12)$
15. $\neg p(B(S))$
16. $sz(B(S))$

4., 15., és 16. -ből

17. $p(A(B(S))) \quad \sigma2/ B(S))$

3. $sz(\sigma1) \quad p(\sigma1) \quad sz(B(\sigma1))$
4. $\neg sz(\sigma2) \quad p(\sigma2) \quad p(A(\sigma2))$
5. $\neg sz(\sigma3) \quad \neg p(\sigma3) \quad \neg sz(K(\sigma3))$
6. $\neg sz(\sigma4) \quad sz(A(\sigma4))$
7. $\neg sz(\sigma5) \quad \neg sz(K(\sigma5))$
8. $sz(\sigma6) \quad sz(B(\sigma6))$
9. $\neg p(\sigma7) \quad p(B(\sigma7))$
10. $\neg p(\sigma8) \quad p(K(\sigma8))$
11. $p(\sigma9) \quad \neg p(K(\sigma9))$
12. $p(\sigma10) \quad \neg p(B(\sigma10))$
13. $p(\sigma11) \quad p(A(\sigma11))$
14. $sz(\sigma12) \quad \neg p(\sigma12)$
15. $\neg p(B(S))$
16. $sz(B(S))$
17. $p(A(B(S)))$

6. és 16. -ből

18. $sz(A(B(S)))$

$\sigma4/ B(S)$

3. $sz(\sigma1) \quad p(\sigma1) \quad sz(B(\sigma1))$
4. $\neg sz(\sigma2) \quad p(\sigma2) \quad p(A(\sigma2))$
5. $\neg sz(\sigma3) \quad \neg p(\sigma3) \quad \neg sz(K(\sigma3))$
6. $\neg sz(\sigma4) \quad sz(A(\sigma4))$
7. $\neg sz(\sigma5) \quad \neg sz(K(\sigma5))$
8. $sz(\sigma6) \quad sz(B(\sigma6))$
9. $\neg p(\sigma7) \quad p(B(\sigma7))$
10. $\neg p(\sigma8) \quad p(K(\sigma8))$
11. $p(\sigma9) \quad \neg p(K(\sigma9))$
12. $p(\sigma10) \quad \neg p(B(\sigma10))$
13. $p(\sigma11) \quad p(A(\sigma11))$
14. $sz(\sigma12) \quad \neg p(\sigma12)$
15. $\neg p(B(S))$
16. $sz(B(S))$
17. $p(A(B(S)))$
18. $sz(A(B(S)))$

5., 17., és 18. -ből

19. $\neg sz(K(A(B(S)))) \quad \sigma3/ A(B(S))$

5. $\neg \text{sz}(\sigma 3) \neg p(\sigma 3) \neg \text{sz}(K(\sigma 3))$

6. $\neg \text{sz}(\sigma 4) \text{sz}(A(\sigma 4))$

7. $\neg \text{sz}(\sigma 5) \neg \text{sz}(K(\sigma 5))$

8. $\text{sz}(\sigma 6) \text{sz}(B(\sigma 6))$

9. $\neg p(\sigma 7) p(B(\sigma 7))$

10. $\neg p(\sigma 8) p(K(\sigma 8))$

11. $p(\sigma 9) \neg p(K(\sigma 9))$

12. $p(\sigma 10) \neg p(B(\sigma 10))$

13. $p(\sigma 11) p(A(\sigma 11))$

14. $\text{sz}(\sigma 12) \neg p(\sigma 12)$

15. $\neg p(B(S))$

16. $\text{sz}(B(S))$

17. $p(A(B(S)))$

18. $\text{sz}(A(B(S)))$

19. $\neg \text{sz}(K(A(B(S))))$

9. és 16. -ből

20. $p(K(A(B(S))))$

$\sigma 8/A(B(S))$

5. $\neg \text{sz}(\sigma 3) \neg p(\sigma 3) \neg \text{sz}(K(\sigma 3))$

6. $\neg \text{sz}(\sigma 4) \text{sz}(A(\sigma 4))$

7. $\neg \text{sz}(\sigma 5) \neg \text{sz}(K(\sigma 5))$

8. $\text{sz}(\sigma 6) \text{sz}(B(\sigma 6))$

9. $\neg p(\sigma 7) p(B(\sigma 7))$

10. $\neg p(\sigma 8) p(K(\sigma 8))$

11. $p(\sigma 9) \neg p(K(\sigma 9))$

12. $p(\sigma 10) \neg p(B(\sigma 10))$

13. $p(\sigma 11) p(A(\sigma 11))$

14. $\text{sz}(\sigma 12) \neg p(\sigma 12)$

15. $\neg p(B(S))$

16. $\text{sz}(B(S))$

17. $p(A(B(S)))$

18. $\text{sz}(A(B(S)))$

19. $\neg \text{sz}(K(A(B(S))))$

20. $p(K(A(B(S))))$

14. és 20. -ből

21. $\text{sz}(K(A(B(S))))$

$\sigma 12/K(A(B(S)))$

5. $\neg \text{sz}(\sigma 3) \neg p(\sigma 3) \neg \text{sz}(K(\sigma 3))$

6. $\neg \text{sz}(\sigma 4) \text{sz}(A(\sigma 4))$

7. $\neg \text{sz}(\sigma 5) \neg \text{sz}(K(\sigma 5))$

8. $\text{sz}(\sigma 6) \text{sz}(B(\sigma 6))$

9. $\neg p(\sigma 7) p(B(\sigma 7))$

10. $\neg p(\sigma 8) p(K(\sigma 8))$

11. $p(\sigma 9) \neg p(K(\sigma 9))$

12. $p(\sigma 10) \neg p(B(\sigma 10))$

13. $p(\sigma 11) p(A(\sigma 11))$

14. $\text{sz}(\sigma 12) \neg p(\sigma 12)$

15. $\neg p(B(S))$

16. $\text{sz}(B(S))$

17. $p(A(B(S)))$

18. $\text{sz}(A(B(S)))$

19. $\neg \text{sz}(K(A(B(S))))$

20. $p(K(A(B(S))))$

21. $\text{sz}(K(A(B(S))))$

19. és 21. -ből: \emptyset

És az eredmény: Az ágens igenis képes megvalósítani a feladatot, ráadásul σ_{12} állapotban. Mi is ez az állapot?

$\sigma_{12} = K(A(B(S))) =$
eredmény(**Kimegy**,
eredmény(**Átfest**,
eredmény(**Bemegy**, **S**)))

Megvalósítja (akkor meglesz a kívánt állapot), ha:

Bemegy → **Átfest** → **Kimegy**
S ----- S1 ----- S3 ----- S4 (szituációk)

cselekvési sorozatot visz véghez.

A szükséges cselekvési sorozatot tehát előre logikailag **kitervelte!**

Prover9

```
-szoba(s0).  
-piros(s0).  
all x (-szoba(x) -> szoba(er(be,x))).  
all x (szoba(x) & -piros(x) -> szoba(er(at,s)) & piros(er(at,x))).  
all x (szoba(x) -> -szoba(er(ki,x))).  
all x (szoba(x) -> szoba(er(at,x))).  
all x (-piros(x) -> -piros(er(be,x))).  
all x (piros(x) -> piros(er(be,x))).  
all x (-piros(x) -> -piros(er(ki,x))).  
all x (piros(x) -> piros(er(ki,x))).  
szoba(y) | -piros(y)    # answer(y).
```

```
===== PROOF =====  
% Proof 1 at 0.01 (+ 0.03) seconds: er(ki,er(at,er(be,s0))).  
...  
1 (all x (-szoba(x) -> szoba(er(be,x)))) # label(non_clause). [assumption].  
2 (all x (szoba(x) & -piros(x)  
   -> szoba(er(at,s)) & piros(er(at,x)))) # label(non_clause). [assumption].  
  
11 szoba(x) | szoba(er(be,x)). [clausify(1)].  
...  
76 $F # answer(er(ki,er(at,er(be,s0)))). [resolve(70,a,20,b),unit_del(a,75)].  
===== end of proof =====
```