PDV 11 2020/2021

Vzájemné vyloučení procesů

Michal Jakob
michal.jakob@fel.cvut.cz
Centrum umělé inteligence, katedra počítačů, FEL ČVUT

Příklad (zjednodušený)

Bankovní server v cloudu.

Dva zákazníci současně vloží 10 000 Kč skrze vkladový bankomat na jeden stejný účet.

- oba bankomaty si přečtou původní zůstatek na účtu (1 000 Kč)
- oba bankomaty k zůstatku přičtou lokálně vklad (=11 000 Kč)
- oba bankomaty výsledný zůstatek uloží na server

Právě jste ztratili 10 000 Kč!

Je třeba zaručit, že v jeden okamžik provádí aktualizaci zůstatku **maximálně jeden** bankomat
(a ostatní procesy jsou z něj **vyloučeny**).

Další příklady

Distribuovaný souborový systém

- uzamykání souborů a adresářů

Přístup k distribuovaným objektům

- zajistit, že v jednom okamžiku má přístup k objektu maximálně jeden proces

Koordinace serverů

- výpočet/zpracování je rozdělen přes několik serverů
- servery koordinují pomoci zámků

Problém vzájemného vyloučení procesů (mutual exclusion)

Kritická sekce (KS): část kódu (všech procesů), u které potřebujeme zaručit, že ji vykonává v každém okamžiku **maximálně jeden proces**.

Dvě funkce

- **enter()** pro vstup k KS
- **exit()** pro výstup z KS

Příklad

Bankomat 1

```
enter(S);
// začátek přístup ke zdroji
přečti zůstatek ze zázamu;
přičti vklad;
aktualizuj záznam o zůstatku;
// konec přístupu ke zdroji
exit(S);
```

Bankomat 2

```
enter(S);
// začátek přístup ke zdroji
přečti zůstatek ze zázamu;
přičti vklad;
aktualizuj záznam o zůstatku;
// konec přístupu ke zdroji
exit(S);
```

Jak řešit vyloučení procesu?

Jeden OS
(Všechny procesy v jednom OS na jednom počítači nebo VM.)

Můžeme použít semafory, mutexy, monitor a další abstrakce poskytované OS založené na **sdílené paměti**.

Distribuovaný systém
(procesy komunikují posíláním zpráv)

Potřebujeme **distribuovaný protokol/algoritmus**.

Korektnost distribuovaného výpočtu

Živost (Liveness)

Garance, že v DS **časem** dojde k něčemu **dobrému** (bude dosažen žádoucí stav).

Příklady:

- Distribuovaný výpočet: výpočet skončí.
- Konsensus: všechny proces se shodnou na výstupní hodnotě.
- Úplnost při detekci selhání: každé selhání je časem detekováno.

Bezpečnost (Safety)

Garance, že v DS **nikdy** nedojde k něčemu **špatnému** (nebude dosažen nežádoucí stav).

Příklady:

- Nedojde k uváznutí (deadlocku)
- Žádný objekt se nestane sirotkem
- Přesnost při detekci selhání
- Konsensus: Žádné dva procesy nevyprodukují různý výstup.

Požadavky na algoritmus pro vyloučení procesu

Bezpečnost: nejvýše jeden proces v kritické sekci v kterémkoliv okamžiku

Živost: každý požadavek na vstup do kritické sekce je časem uspokojen

Uspořádání (volitelný): předchází-li žádost jedno procesu kauzálně žádost druhé ho procesu, bude vstup nejprve dovolen prvnímu procesu

Model

Skupina N procesů.

Procesy **neselhávají**.

FIFO perfektní komunikační kanál mezi každým párem procesů, tj. zprávy se neduplikují, nevznikají, neztrácejí a jsou doručovány v pořadí odeslání.

Asynchronní systém: neznáma, ale **konečná latence.**

Přístupy

Tokenové

Beztokenové

Okrskové (quorum-based)

Centralizovaný algoritmus

Centralizovaný algoritmu

Zvolíme **koordinátora** (pomocí algoritmu volby lídra/koordinátora)

Koordinátor spravuje:

- speciální **token**, který umožnuje držiteli vstup do KS
- **frontu** požadavků na vstup do kritické sekce (KS)

Centralizovaný algoritmus

Akce libovolného procesu

enter()

pošli požadavek koordinátorovi

čekej na přijetí TOKEN od koordinátora; po přijetí TOKENu vstup do KS

exit()

předej TOKEN zpět koordinátorovi

Akce koordinátora

Po přijetí požadavku z procesu P_i

if (koordinátor má TOKEN)

předej TOKEN procesu P_i

else

přidej P_i do **`fronty`**

Po přijetí TOKENu od procesu P_i

if (**`fronta`** není prázdná)

vyzvedni proces z hlavy **`fronty`** a pošli mu TOKEN

else

uchovej TOKEN

Analýza centralizovaného algoritmu

Bezpečnost: Maximálně jeden proces v KS

- splněno: máme pouze jeden token

Živost: na každý požadavek časem dojde

- fronta má maximálně N čekajících procesů
- pokud každý proces časem doběhne a nedochází k selhání, tak je živost garantována

Uspořádání: přístup je poskytován v pořadí došlých žádostí

- šlo by uspořádat logickými hodinami

Analýza výkonnosti

Efektivní vyloučení procesu vyžaduje **méně koordinačních zpráv** a procesy mají **kratší čekací dobu** na vstup.

Komunikační zátěž: počet zpráv poslaných při každém vstupu a výstupu do/z KS.

Zpoždění klienta: zpoždění klientského procesu při každém vstupu do KS, tj. když žádné jiné procesy nečekají (tj. když je KS volná).

Synchronizační zpoždění: časový interval mezi vystoupením jednoho procesu KS a vstupem následujícího procesu do KS (když je pouze jeden čekající proces).

Analýza výkonosti centralizovaného algoritmu

Komunikační zátěž:

- vstup: **2** zprávy
- výstup: **1** zpráva

Zpoždění klienta:

- **2** komunikační latence (odeslání požadavku a obdržení tokenu)

Synchronizační zpoždění

- **2** komunikační latence (vrácení tokenu a obdržení tokenu)

Ale: Koordinátor je centrální **úzké hrdlo** (a centrální bod selhání).

Kruhový algoritmus
(Ring-based algorithm)

Kruhový algoritmus

Velmi jednoduchý algoritmus.

N procesů organizovaných **do kruhu**.

Každý proces může poslat zprávu svému **následníkovi**.

Koluje právě **jeden TOKEN**.

Kruhový algoritmus

Akce libovolného procesu

enter()

vyčkej, dokud nedostaneš TOKEN;

po obdržení vstup do KS;

exit() // předpokládá, že proces je v KS

pošli TOKEN následníkovi;

Jinak pokud obdržíš TOKEN a nejsi aktuálně v KS, tak předej TOKEN následníkovi.

Kruhový algoritmus

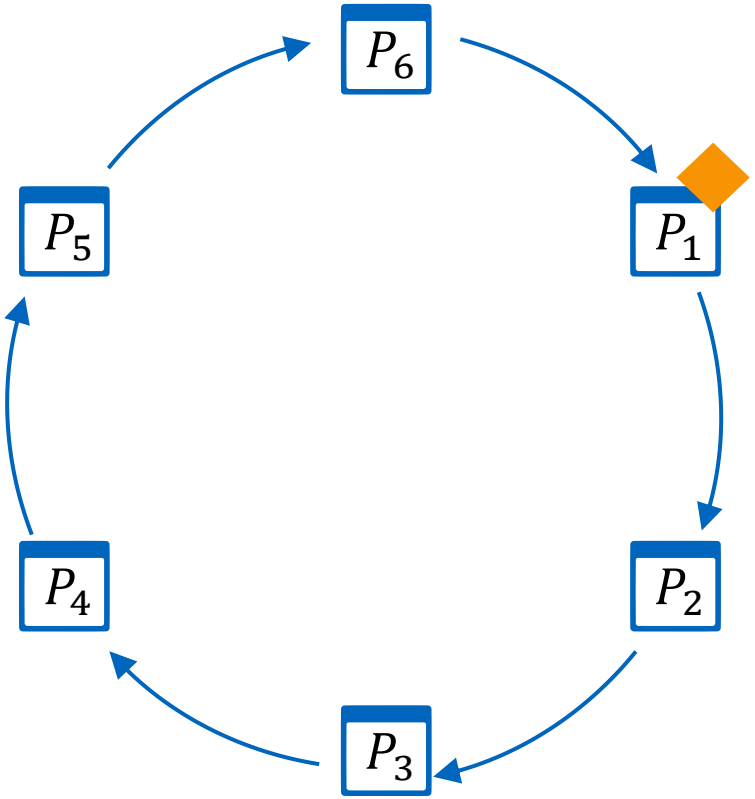

Má aktuálně TOKEN → může vstoupit do KS

TOKEN předáván následníkovi

Má aktuálně TOKEN → může vstoupit do KS

proces

TOKEN

Analýza kruhové algoritmu

Bezpečnost: splněná – právě jeden TOKEN.

Živost: TOKEN časem oběhnou celý kruh (nepředpokládáme selhání).

Komunikační zátěž:

- vstup: implicitně N zpráv skrze systém (kolují neustále)
- výstup: 1 zpráva

Zpoždění klienta: 0 až N komunikačních latencí po žádosti o vstup

- nejlepší případ: žádající proces už má TOKEN
- nejhorší případ: TOKEN zrovna odeslán následníkovi

Synchronizační zpoždění: 1 až $N - 1$ komunikačních latencí

- nejlepší případ: proces žádající vstup je následníkem procesu opouštějící KS
- nejhorší případ: proces žádající vstup je předchůdce procesu opouštějící KS

Analýza kruhové algoritmu

Zpoždění klienta a synchronizační zpoždění kruhového algoritmu je $\boldsymbol{O(N)}$.

Můžeme zlepšit?

Ricart-Agrawalův Algoritmus

Algoritmus Ricart-Agrawala

Klasický beztokenový algoritmus z roku 1981.

Nepoužívá TOKEN, ale využívá **kauzalitu** (skalární hodiny) a **multicast** (HW nebo SW).

Má nižší synchronizační zpoždění a zpoždění klienta než kruhový algoritmus a zároveň nepotřebuje centrální proces.

Logika Ricart-Agrawala

Každý proces si udržuje logickou proměnou **`stav`** (inicializovanou na RELEASED) a **`seznam`** požadavků na vstup.

P_i: enter()

nastav `stav` na WANTED $\langle T_i, i \rangle$;

pošli multicast REQUEST $\langle T_i, i \rangle$ všem procesům, kde T_i = aktuální Lamportův logický čas v P_i;

čekej dokud všechny procesy nepošlou zpět OK;

po přijetí OK: **změň `stav`** na HELD a **vstup** do KS

P_i: po přijetí REQUEST$\langle T_j, P_j \rangle$, $i \neq j$

if (**`stav`** = HELD) nebo (**`stav`** = WANTED $\langle T_i, i \rangle$ a $\langle T_i, \mathrm{i} \rangle < \langle T_j, \mathrm{j} \rangle$)

    přidej REQUEST do **`seznamu`** čekajících požadavků;

else

    pošli OK do P_j;

P_i : exit()

nastav `stav` na RELEASED;

pošli OK všem čekajícím procesům ze **`seznamu`**;

Příklad

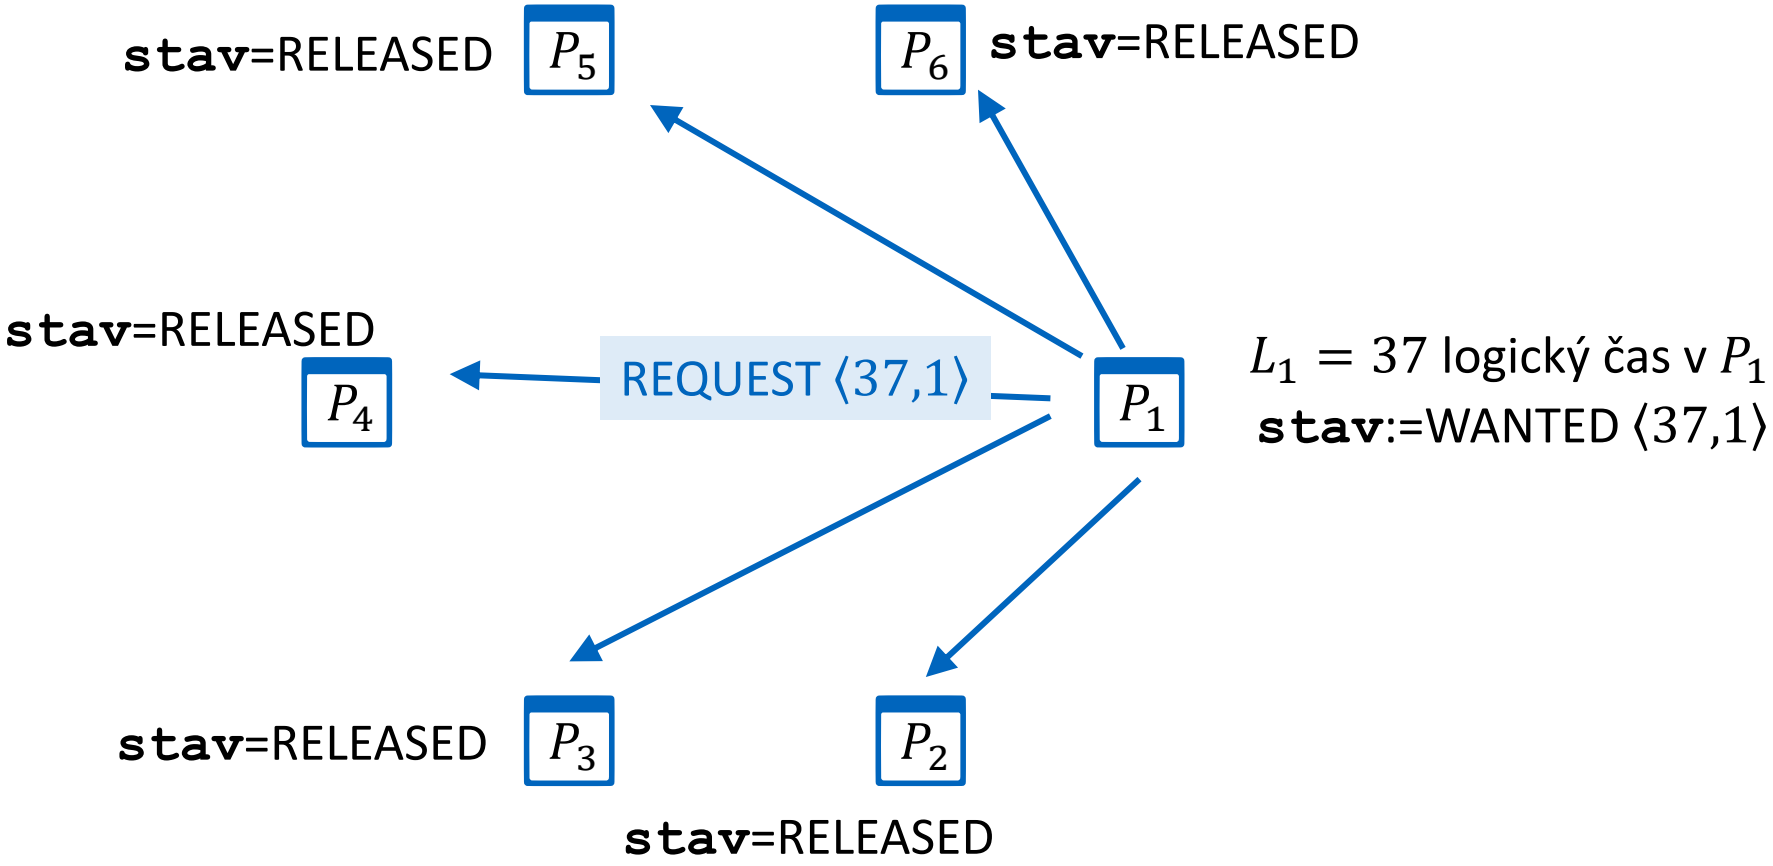
stav=RELEASED
P_5
P_6
stav=RELEASED
stav=RELEASED
P_4
REQUEST ⟨37,1⟩
P_1
$L_1 = 37$ logický čas v P_1
stav:=WANTED ⟨37,1⟩
stav=RELEASED
P_3
P_2
stav=RELEASED

Příklad

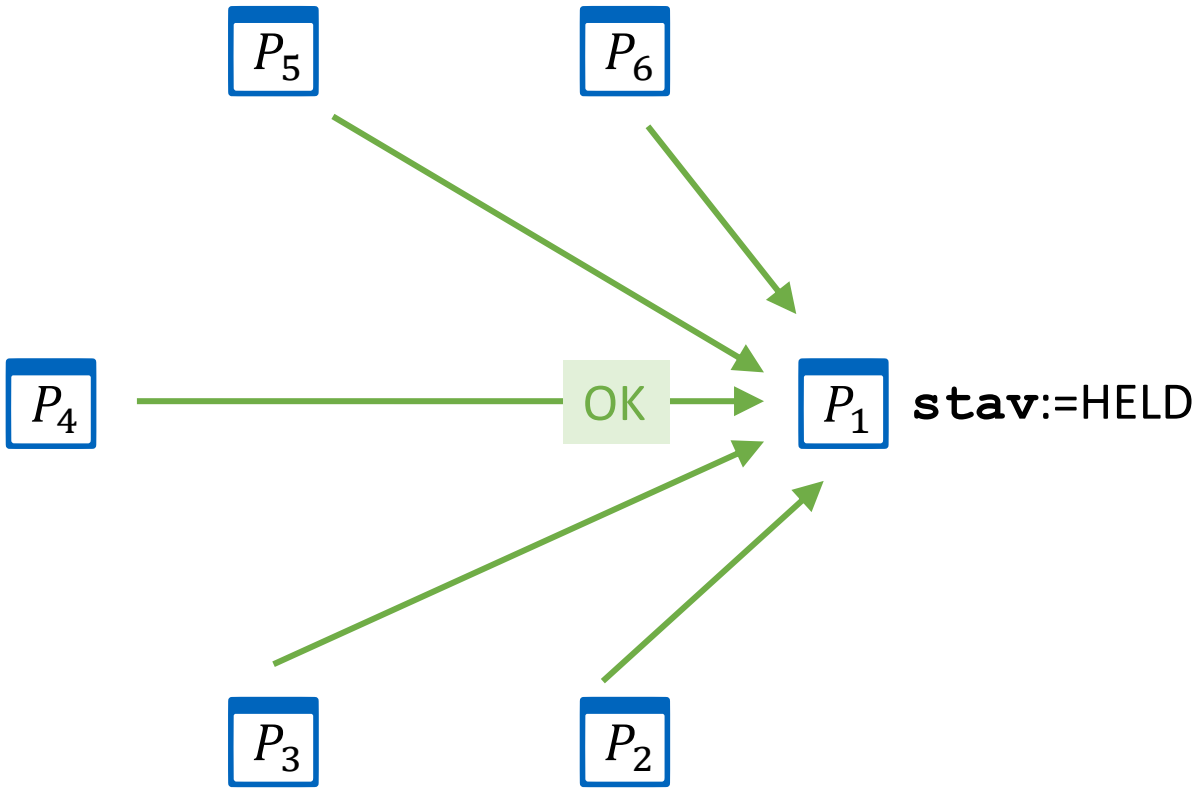

Příklad

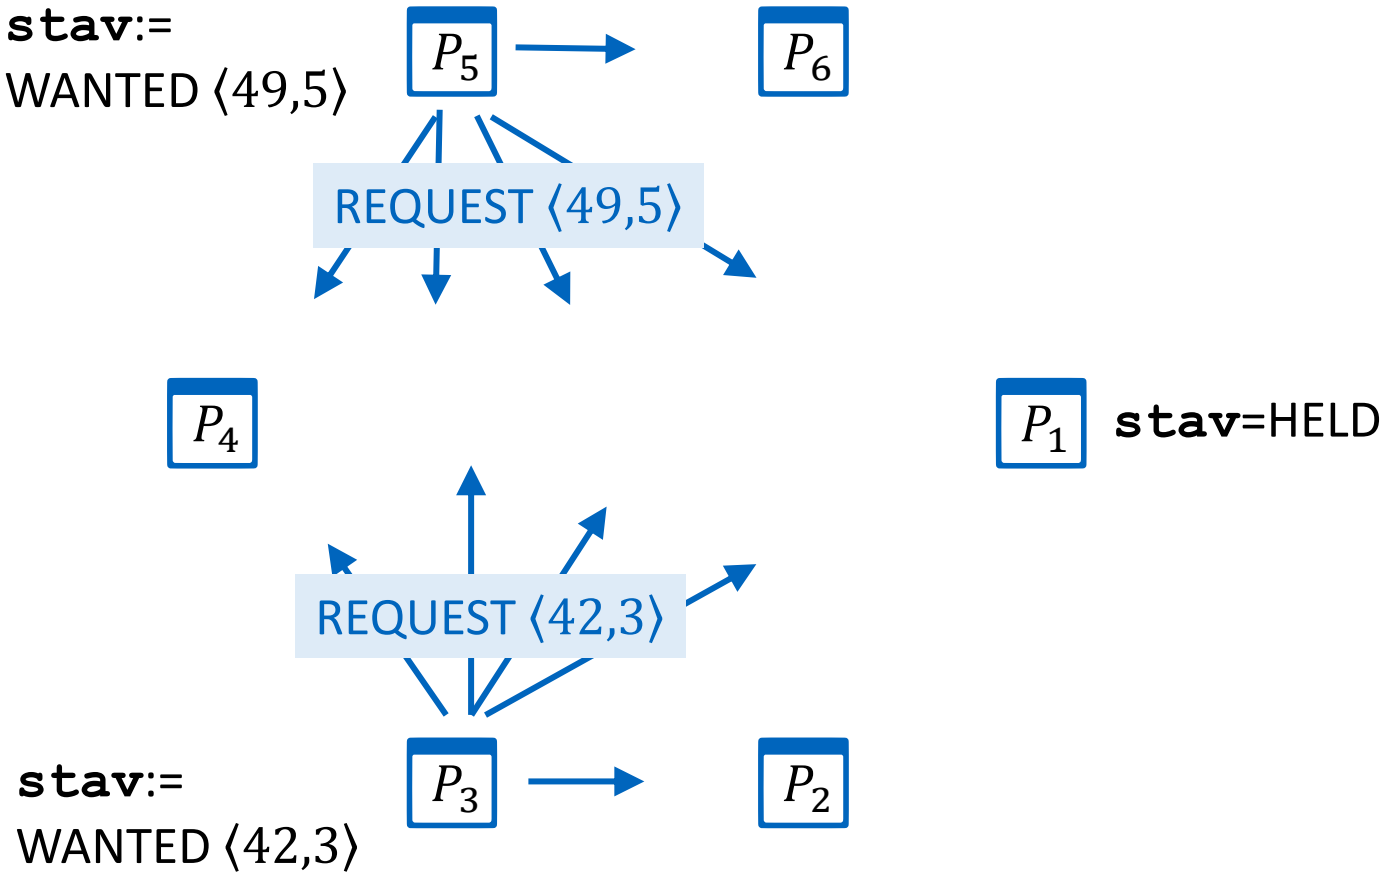
stav:=
WANTED ⟨49,5⟩
P_5
P_6
REQUEST ⟨49,5⟩
P_4
P_1
stav=HELD
REQUEST ⟨42,3⟩
stav:=
WANTED ⟨42,3⟩
P_3
P_2

Příklad

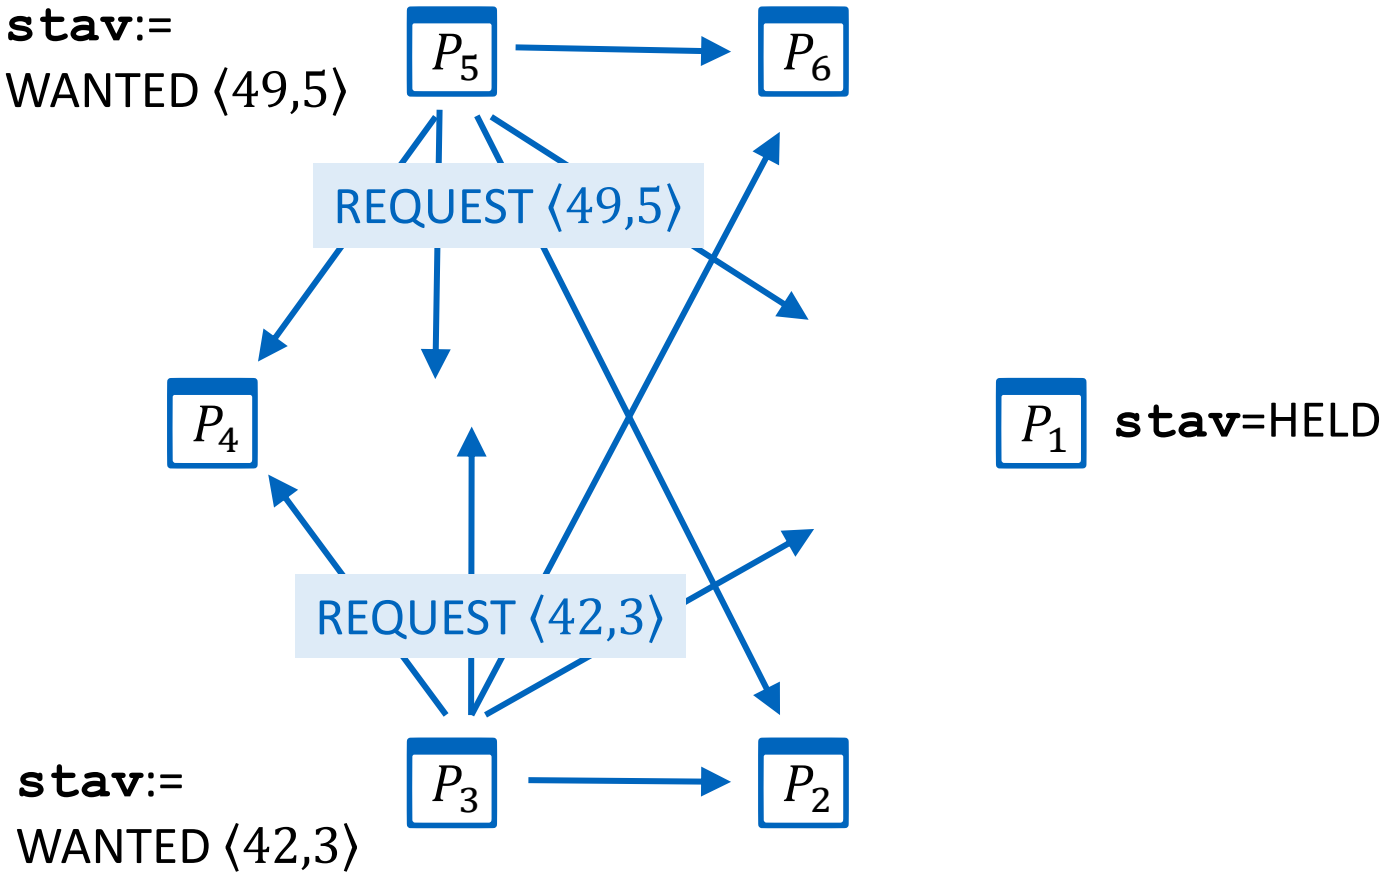
stav:=
WANTED ⟨49,5⟩
P_5
P_6
REQUEST ⟨49,5⟩
P_4
P_1
stav=HELD
REQUEST ⟨42,3⟩
stav:=
WANTED ⟨42,3⟩
P_3
P_2

Příklad

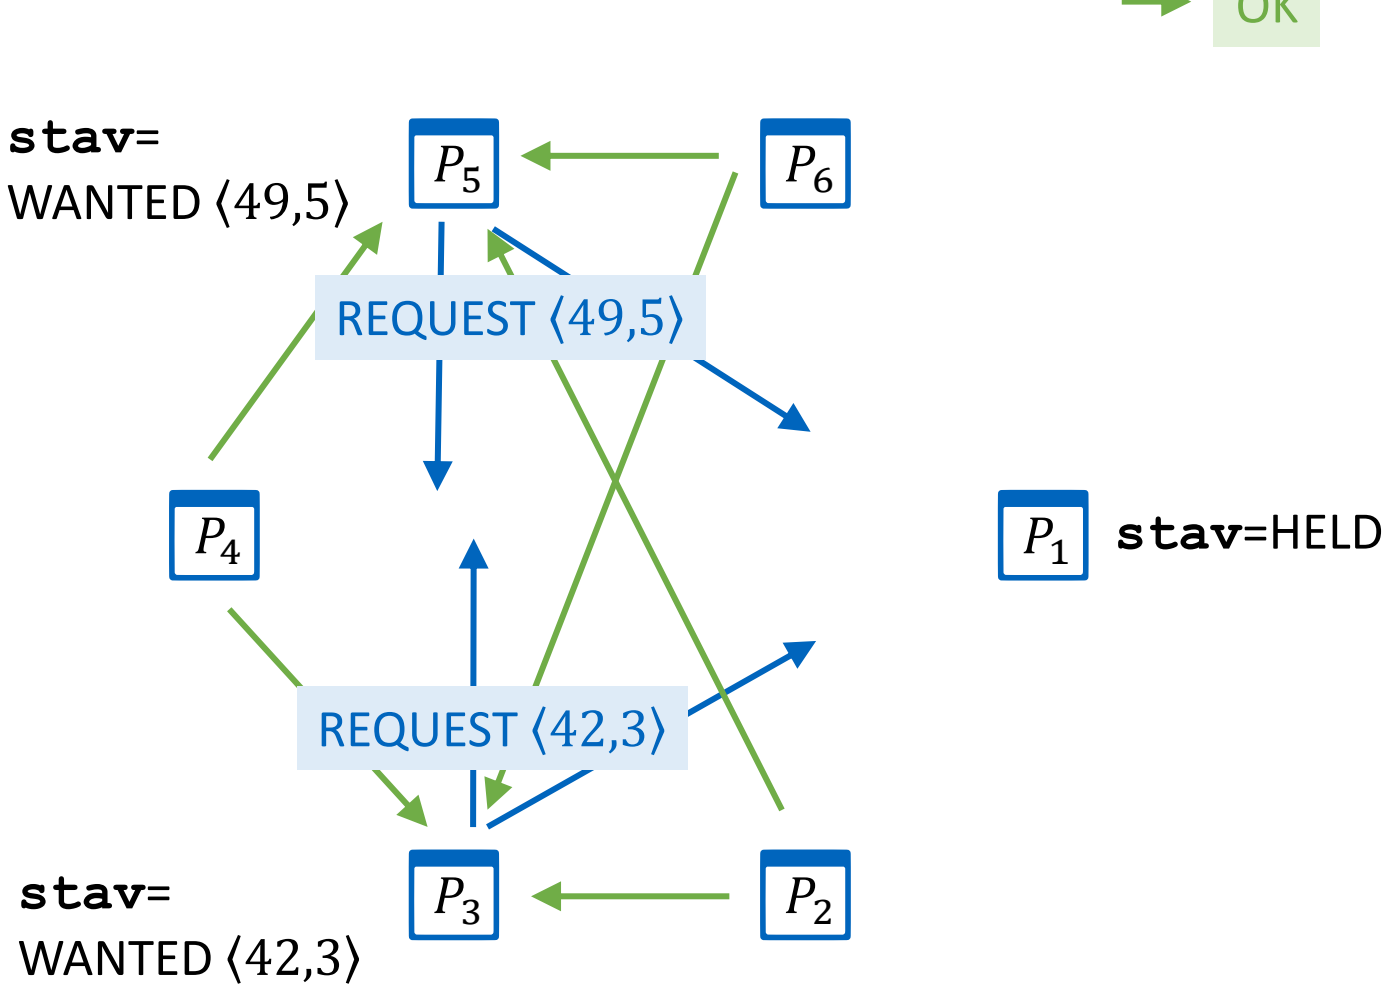
OK
stav=
WANTED ⟨49,5⟩
P_5
P_6
REQUEST ⟨49,5⟩
P_4
P_1
stav=HELD
REQUEST ⟨42,3⟩
stav=
WANTED ⟨42,3⟩
P_3
P_2

Příklad

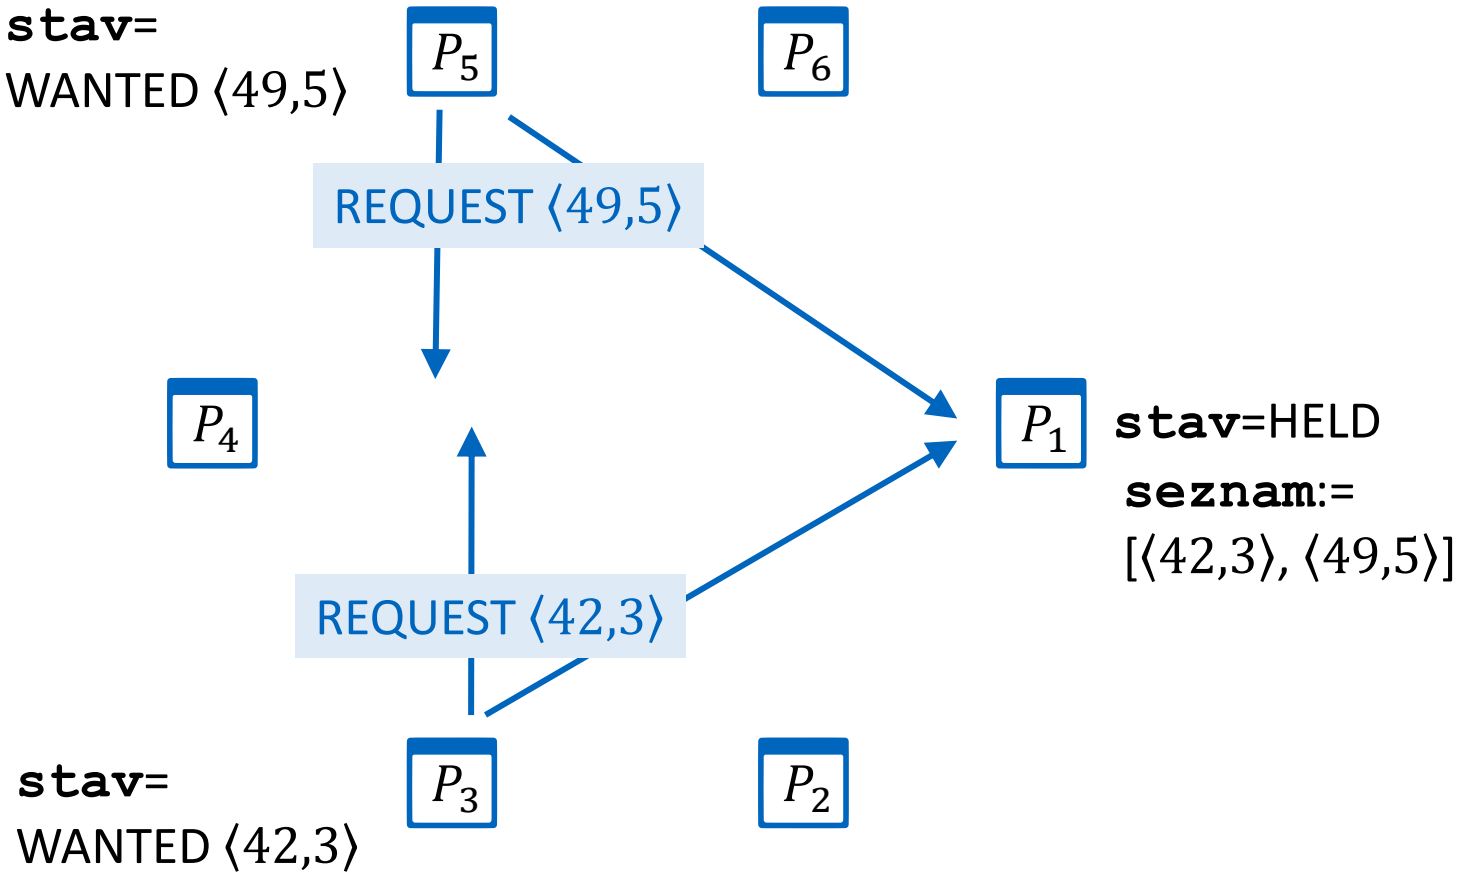
stav=
WANTED ⟨49,5⟩
P_5
P_6
REQUEST ⟨49,5⟩
P_4
P_1
stav=HELD
seznam:=
[⟨42,3⟩, ⟨49,5⟩]
REQUEST ⟨42,3⟩
stav=
WANTED ⟨42,3⟩
P_3
P_2

Příklad

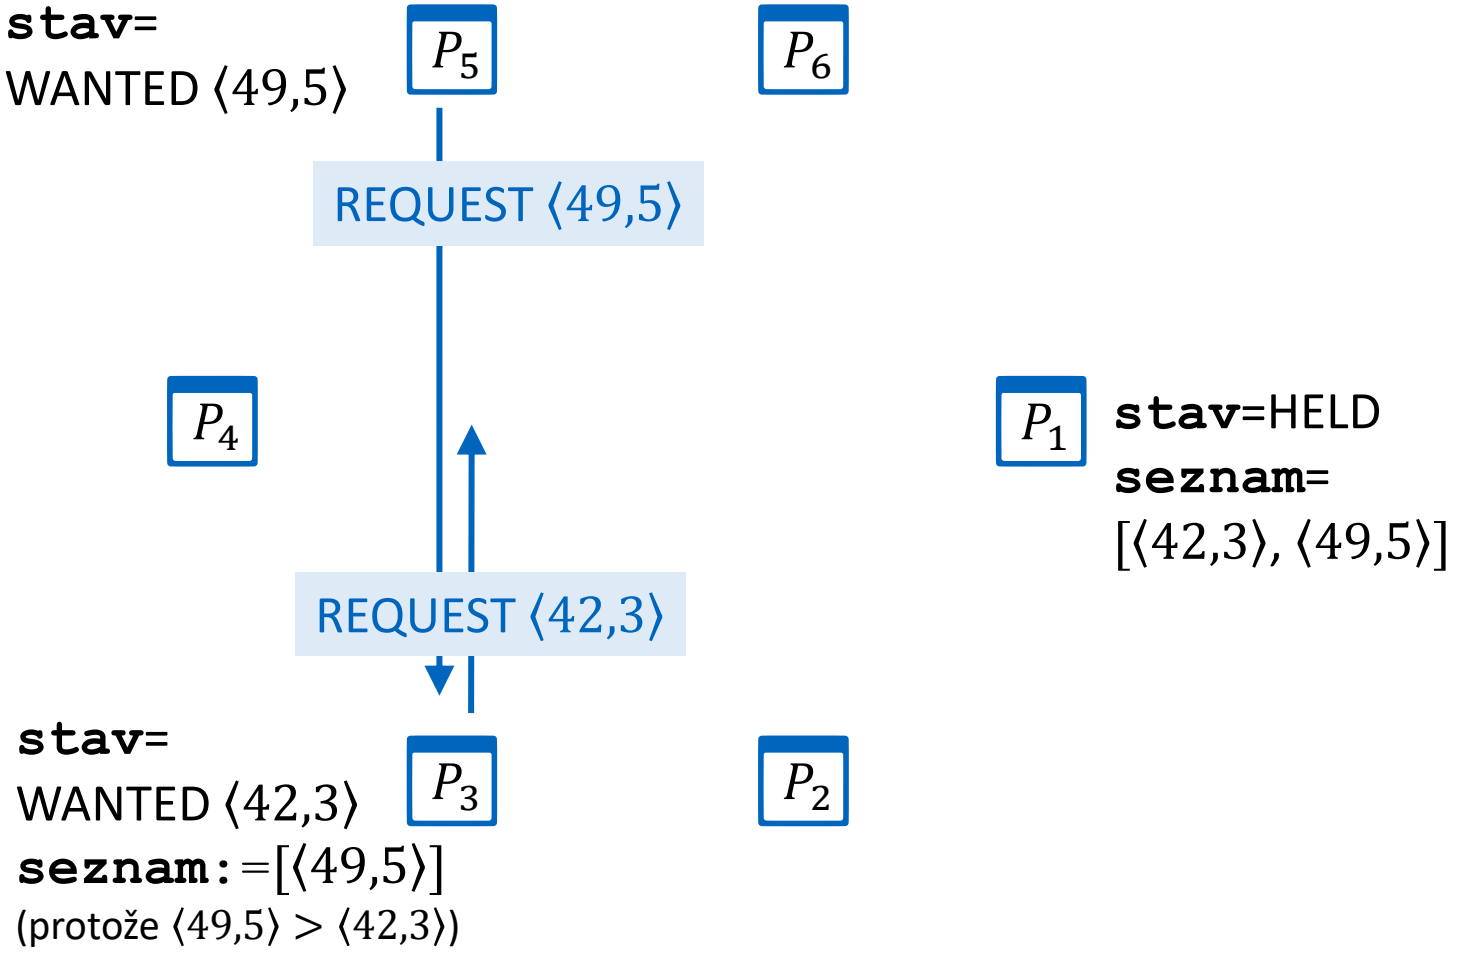
stav=
WANTED ⟨49,5⟩
P_5
P_6
REQUEST ⟨49,5⟩
P_4
P_1
stav=HELD
seznam=
[⟨42,3⟩, ⟨49,5⟩]
REQUEST ⟨42,3⟩
stav=
WANTED ⟨42,3⟩
seznam:=[⟨49,5⟩]
(protože ⟨49,5⟩ > ⟨42,3⟩)
P_3
P_2

Příklad

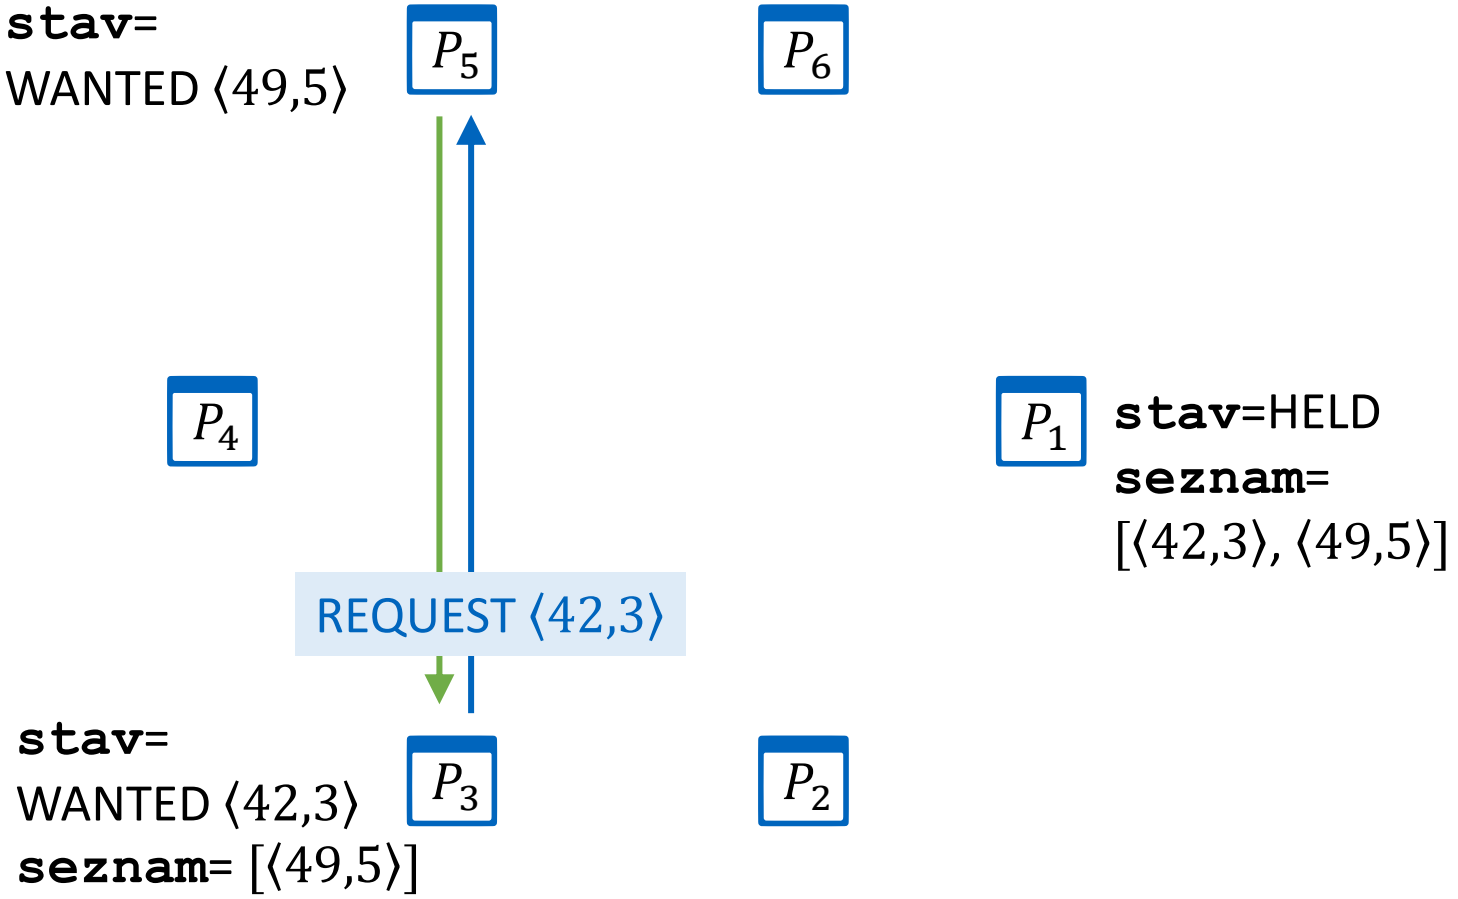
stav=
WANTED ⟨49,5⟩
P_5
P_6
P_4
P_1
stav=HELD
seznam=
[⟨42,3⟩, ⟨49,5⟩]
REQUEST ⟨42,3⟩
stav=
WANTED ⟨42,3⟩
seznam= [⟨49,5⟩]
P_3
P_2

Příklad

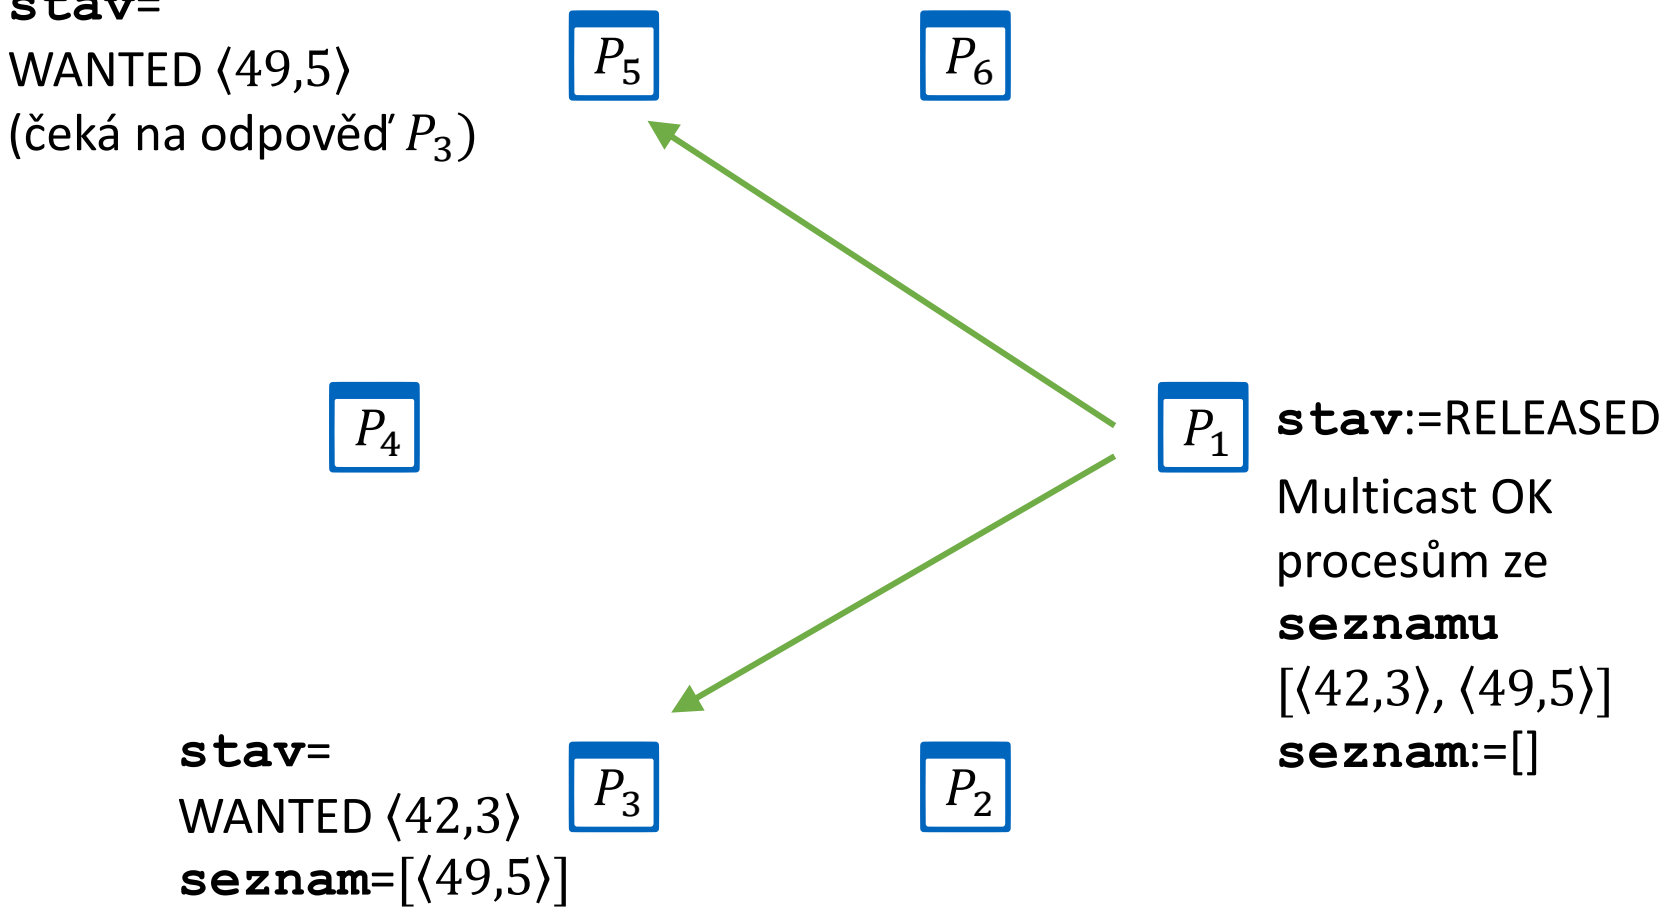
stav=
WANTED ⟨49,5⟩
(čeká na odpověď P_3)
P_5
P_6
P_4
P_1
stav:=RELEASED
Multicast OK procesům ze seznamu
[⟨42,3⟩, ⟨49,5⟩]
seznam:=[]
stav=
WANTED ⟨42,3⟩
seznam=[⟨49,5⟩]
P_3
P_2

Příklad

stav=
WANTED $\langle 49,5 \rangle$
(čeká na odpověď P_3)

P_5

P_6

P_4

P_1

stav:=RELEASED

Multicast OK procesům ze **seznamu**
$[\langle 42,3 \rangle, \langle 49,5 \rangle]$
seznam:=[]

stav:=HELD
seznam=$[\langle 49,5 \rangle]$

P_3

P_2

Příklad

stav=
WANTED ⟨49,5⟩
(čeká ještě na odpověď P_3)

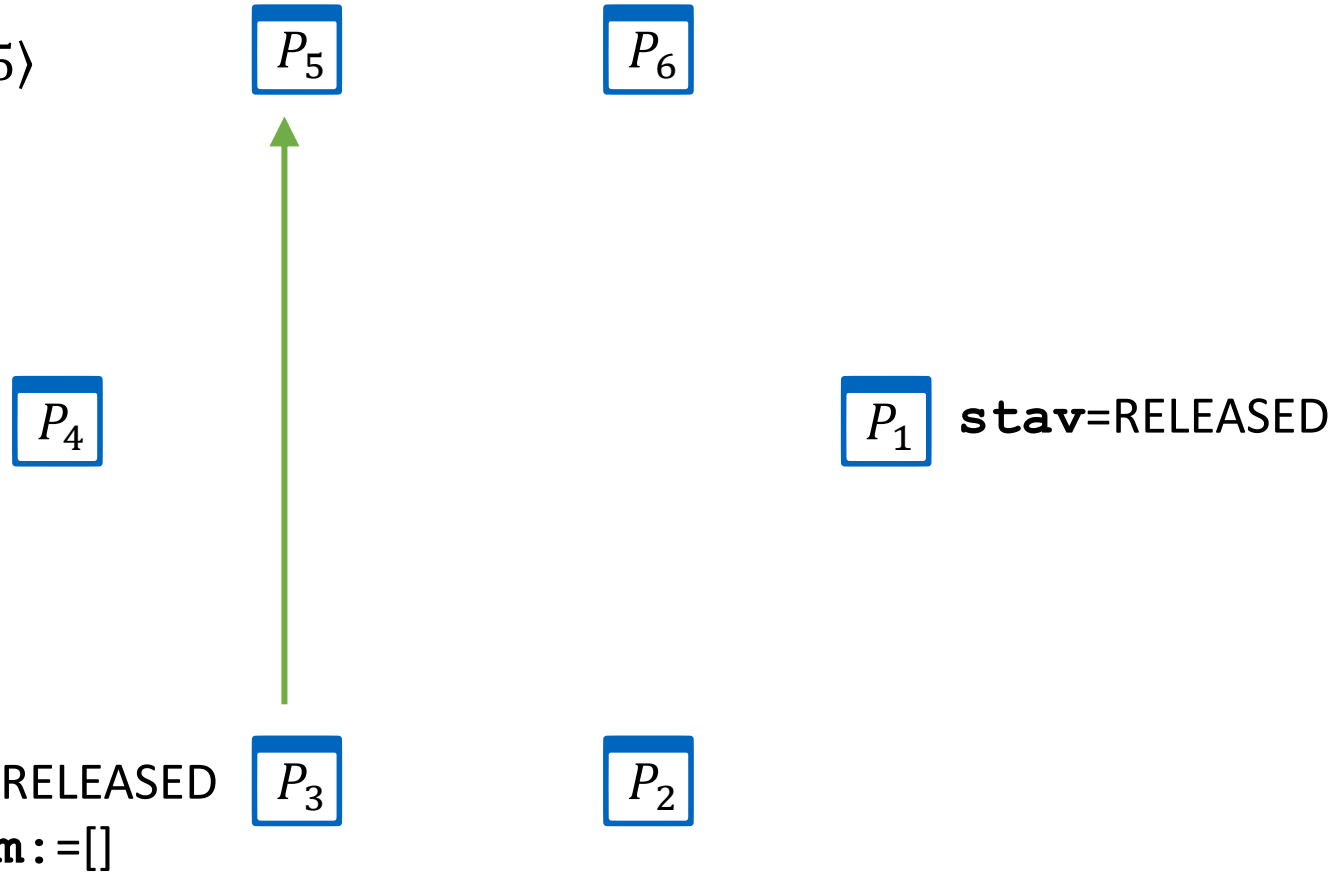

Příklad

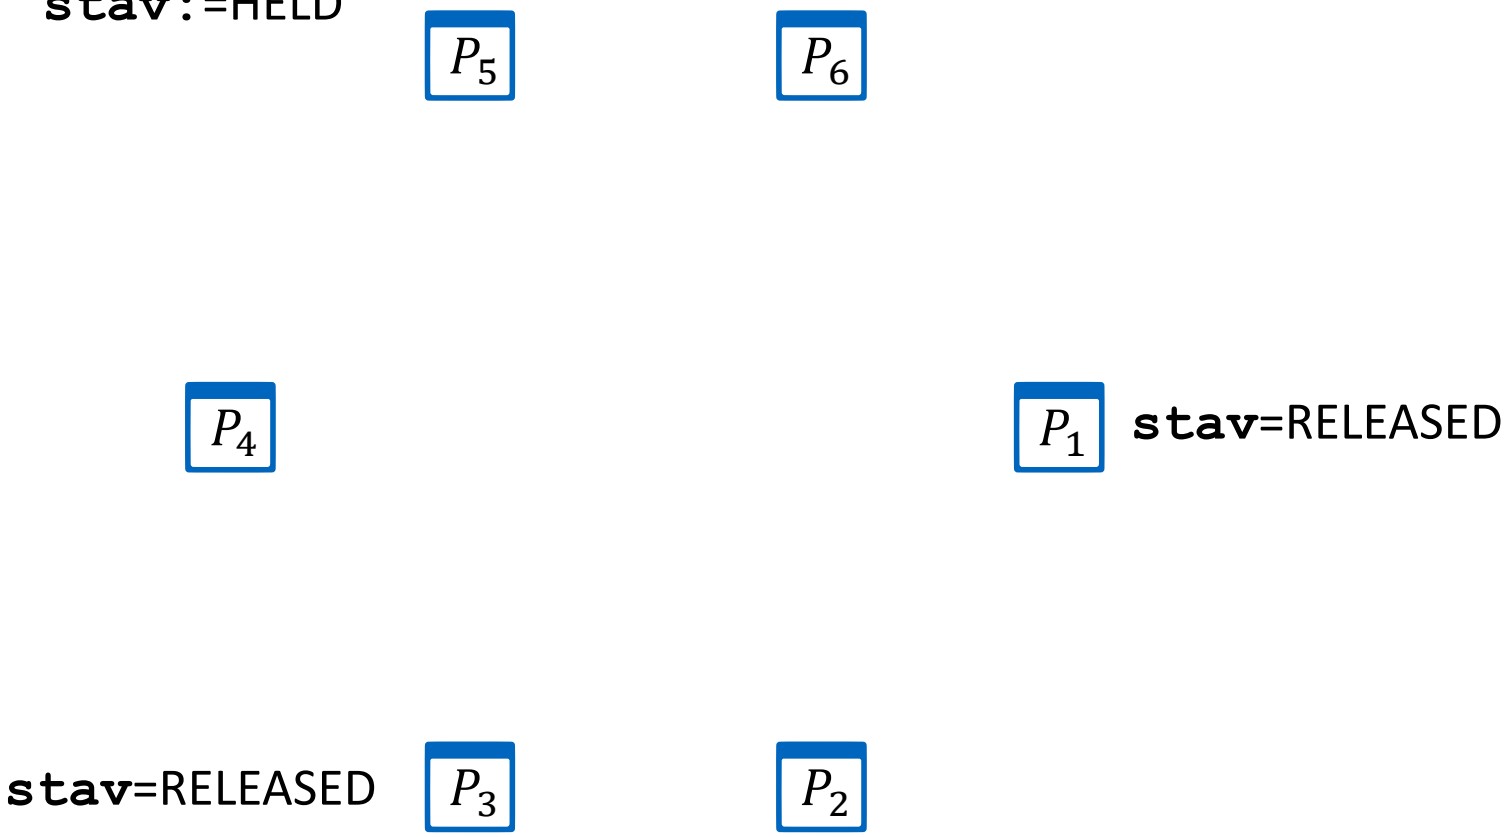

Analýza

Bezpečnost: Dva procesy P_i a P_j nemohou současně získat přístup do KS

- pokud by získaly, musely by si oba vzájemně poslat OK
- tedy $\langle T_i, i \rangle < \langle T_j, j \rangle$ a $\langle T_j, j \rangle < \langle T_i, i \rangle$, což obojí není možné
- co když $\langle T_i, i \rangle < \langle T_j, j \rangle$ a P_i odpověděl na požadavek P_j předtím, než vytvořil vlastní požadavek?
    - ale: kauzalita a Lamportovy časové značky v P_j implikují $T_i > T_j$, což je spor a tedy tato situace nemůže nastat

Analýza

Živost: nejhorší případ – je potřeba počkat než všech $(N-1)$ pošle OK

Pořadí: Požadavky s nižší Lamportovou časovou značkou mají přednost

Analýza

Komunikační zátěž:

- Vstup: $2 * (N - 1)$
  (resp. N pokud je k dispozici nativní multicast)
- Výstup: $N - 1$
  (resp. 1 pokud je k dispozici multicast)

Zpoždění klienta: **1** čas oběhu zprávy

Synchronizační zpoždění: **1** komunikační latence

Analýza

Ve srovnání s centrálním algoritmem jsme odstranili centrální prvek.

Ale: komunikační zátěž narostla na $\boldsymbol{O(N)}$

Lze ji dále snížit?

Maekawův algoritmus

Hlavní myšlenka: pro vstup nepotřebují souhlas všech procesů, ale pouze souhlas všechny z tzv. **volebního okrsku** (voting set).

- Každý proces žádá o vstup pouze procesy ze svého volebního okrsku (tj. ne všechny).
- Každý pár procesů má aspoň jeden společný okrsek.
- Každý proces dává svolení nejvýše jednomu procesu (tj. ne všem)

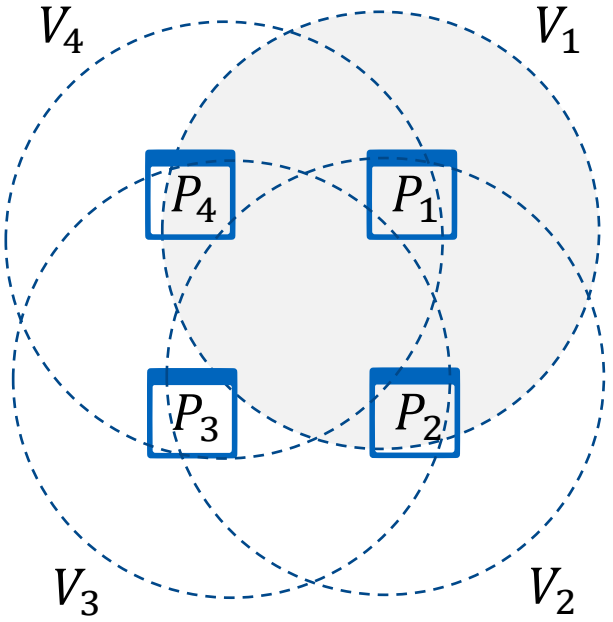

Komunikační složitost Maekawova algoritmu: $\boldsymbol{O(\sqrt{N})}$.

Souhrn

Distribuované vyloučení procesů je důležitý problém v DS.

Klasické algoritmy: centralizovaný, kruhový, Ricart-Agawala, Maekawa.

Všechny mají zaručenou **bezpečnost**, **živost** a **pořadí vstupu**. Liší se v komunikační náročnosti a ve zpožděních pří vstupu/výstupu a synchronizaci.

Algoritmy se vypořádávají s **asynchronicitou**, ale nikoliv se **selháními**.