Tupikud

- Süsteemi mudel
- Tupiku tingimused
- Tupikute käsitlemise meetodid
- Tupikute ennetamine
- Tupikute vältimine
- Tupikute avastamine
- Tupikust taastumine
- Kombineeritud lähenemine

Tupikute probleem

- Tupik — hulk blokeerunud protsesse, millest igaüks ootab mingi ressursi taga, mida kasutab mõni teine neist protsessidest
- Näide: autod kitsal sillal

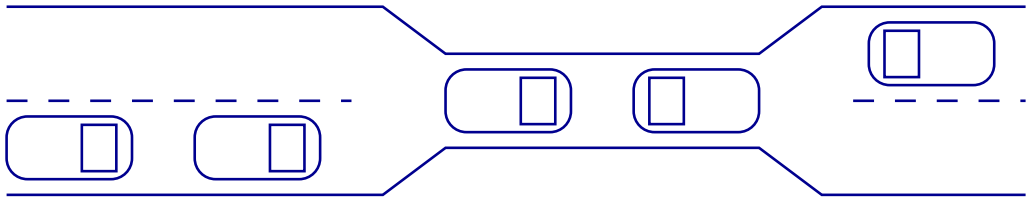

- Näide: 4 ristmikku
- Näide: kaks semafori A ja B, algväärtusega 1

P_i	P_j
wait(A);	wait(B);
wait(B);	wait(A);

Süsteemi mudel

- Ressursitüübid R_1, R_2, ..., R_m
- Näiteks protsessoriaeg, mäluruum, välisseadmed
- Igast ressursist R_i on W_i instantsi
- Iga protsess kasutab mingit ressurssi niisuguses järjestuses:
  - hõivamine (*request*)
  - kasutamine
  - vabastamine (*release*)

Tupiku tingimused

- Tupiku tekkimiseks peavad olema täidetud kõik järgnevad tingimused:
  - Vastastikune välistamine — mingit ressurssi saab korraga kasutada ainult üks protsess
  - Hoidmine ja ootamine — mingi protsess hoiab vähemalt ühte ressurssi enda käes ja ootab järgmise ressursi hõivamisel
  - Pole väljatõrjumist — ressursse vabastatakse ainult vabatahtlikult (pärast kasutamise lõpetamist), neid ei saa jõuga käest ära võtta
  - Tsükliline ootamine — leidub hulk protsesse P_0, P_1, ..., P_n, nii et P_i ootab P_{i+1} taga ($0 \leq i \leq n-1$) ja P_n ootab P_0 taga.

Ressursigraaf

- Protsessidele eraldatud ressursside esitamiseks
- Tippude hulk V ja servade hulk E
- V jaguneb kahte tüüpi tippudeks:
  - $P = \{P_1, \ldots, P_n\}$ — süsteemi kõigi protsesside hulk
  - $R = \{R_1, \ldots, R_m\}$ — süsteemi kõigi ressursitüüpide hulk
- Soovi serv (*request edge*) — suunatud serv $P_i \to R_j$
- Kasutusserv (*assignment edge*) — suunatud serv $R_j \to P_i$

Ressursigraaf

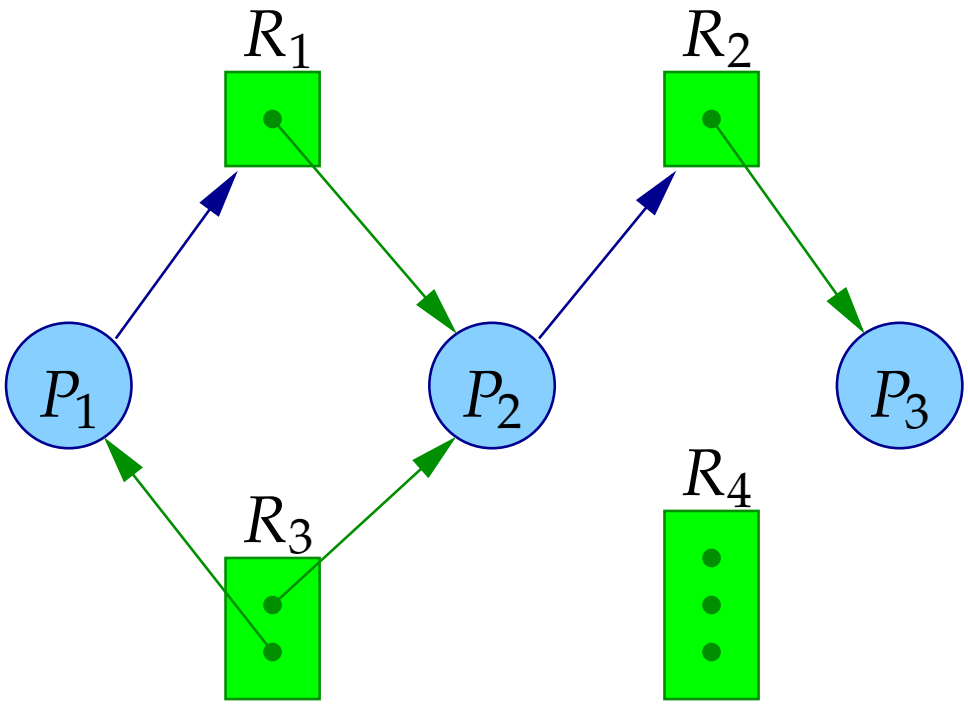

Tupikuga ressursigraaf

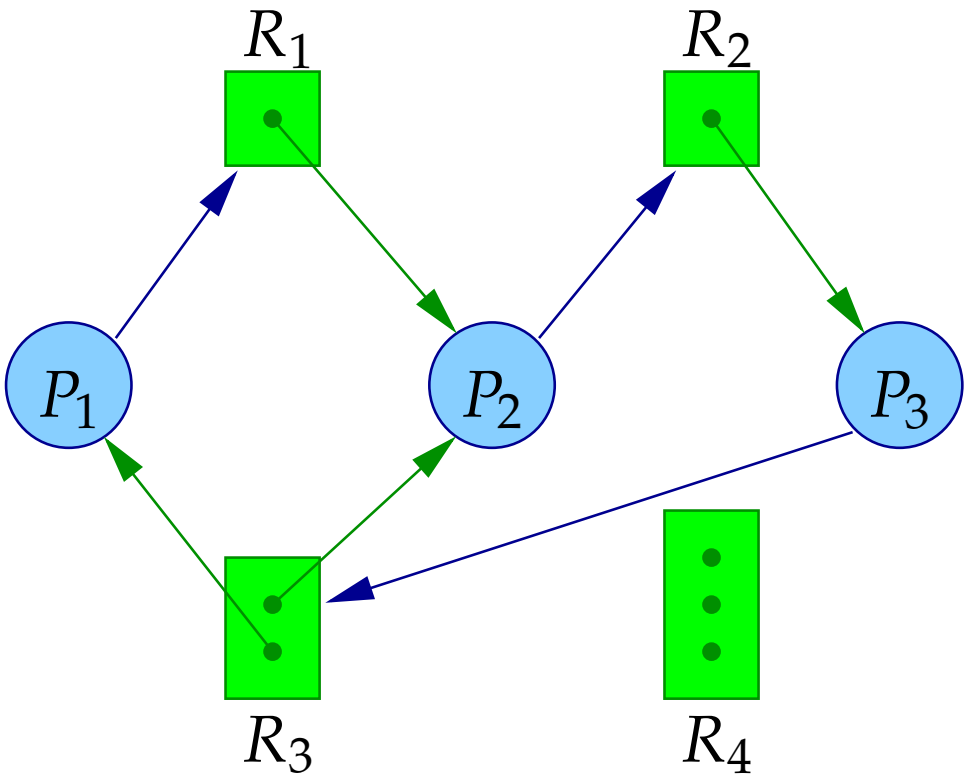

Tsükliga tupikuta ressursigraaf

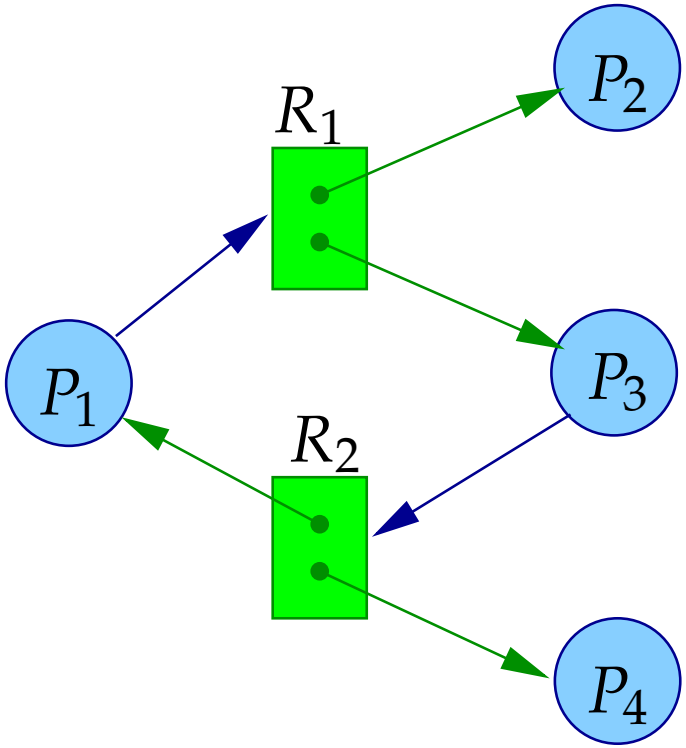

Ressursigraafid ja tupikud

- Graafis pole tsükleid $\Rightarrow$ pole ka tupikuid
- Graafis on tsükkel $\Rightarrow$
  - Kui iga ressurssi on ainult üks, siis tupik
  - Kui mõnda ressurssi on mitu instantsi, siis on tupiku võimalus

Tupikute käsitlemine

- Tupikute ennetamine ja vältimine — garanteerime, et süsteem ei satu kunagi tupikusse
- Tupikute avastamine — lubame süsteemi tupikusse sattuda, avastatud tupikud likvideerime
- Tupikute ignoreerimine — ignoreerime probleemi ja teeme näo, et tupikuid kunagi ei juhtugi
  - Kasutusel enamuse operatsioonisüsteemide poolt, näiteks UNIX

Tupikute ennetamine (1)

- Ingl. *deadlock prevention*
- Põhiidee: piirame võimalusi ressursipäringute tegemiseks, nii et vähemalt üks neljast tupiku tingimusest oleks alati väär
  - Vastastikune välistamine — pole vajalik jagatavate ressursside puhul, siiski kohustuslik mittejagatavate ressursside puhul
  - Hoidmine ja ootamine — garanteerime, et kui protsess küsib mingit ressurssi, siis ta ei omaks teisi ressursse
    * Laseme rakendusel kõik kasutatavad ressursid käivitamise alguses ära küsida või lubame ainult siis uusi ressursse võtta, kui vanad on vabastatud
    * Ebaefektiivne ressursikasutus, võimalik näljutamine

Tupikute ennetamine (2)

- Pole väljatõrjumist — kui protsess hoiab ressursse ja küsib uusi, mida kohe ei saa, siis anname vanad ressursid kah seni vabaks ja ta ootab nüüd ka nende järgi
  - Alternatiiv — kui küsitav ressurss pole vaba, aga selle on hõivanud mõni parajasti ootel olev protsess, võtame selle talt ära
- Tsükliline ootamine — kasutame ressursside täielikku järjestust ja laseme igal protsessil võtta juurde ainult sellist tüüpi ressursse, mille number pole väiksem ühestki olemasolevast

Tupikute vältimine

- Ingl. *deadlock avoidance*
- Süsteem vajab lisainfot selle kohta, kui palju ja missuguseid ressursse protsessid tulevikus kasutada tahavad
- Lihtsaim ja kasulikeim mudel käsib igal protsessil deklareerida maksimaalsed vajadused ressursside kohta
- Tupikute vältimise algoritm uurib dünaamiliselt ressursitabelit, et ei saaks tekkida tsüklilise ootamise situatsiooni
- Ressursside hõivatuse oleku defineerivad vabade ja hõivatud ressursside arvud ja protsesside maksimaalsed nõudmised neile

Ohutud olekud (1)

- Kui protsess nõuab ressurssi, siis süsteem peab otsustama, kas allokeerimise tulemusena oleks olek ohutu
- Olekut loetakse ohutuks, kui leidub ohutu järjestus protsessidest
- Protsesside järjestus $< P_1, P_2, \ldots, P_n >$ on ohutu, kui iga P_i nõudmised saab rahuldada selleks hetkeks vabade ning protsesside P_j ($j < i$) poolt kasutatavate ressurssidega
  - Kui protsessi P_i ressursivajadused pole koheselt rahuldatavad, siis P_i ootab, kuni ressursse kinni hoidvad protsessid P_j on lõpetanud
  - Kui protsessid P_j on lõpetanud, saab protsess P_i vajaminevad ressursid oma käsutusse ning vabastab need peale kasutamist
  - Seejärel saab protsess P_{i+1} talle vajalikud ressursid jne.

Ohutud olekud (2)

- Kui süsteem on ohutus olekus $\Rightarrow$ pole tupikuid
- Kui süsteem on ohtlikus olekus (s.t. pole ohutu) $\Rightarrow$ tupikud on võimalikud
  - Siiski pole kõik ohtlikud olekud tupikud
- Tupikute vältimiseks garanteerime, et süsteem ei satuks ohtlikku olekusse

Ressursigraafi algoritm

- Kui igast ressursist on üks eksemplar, saab ohtlike olekute kindlaks tegemiseks kasutada modifitseeritud ressursigraafi
- Nõudmise serv $P_i \rightarrow R_j$ näitab, et protsess P_i võib nõuda ressurssi R_j (tähistame sinisega)
- Nõudmise serv muutub soovi servaks, kui protsess reaalselt nõuab seda ressurssi (tähistame rohelisega)
- Ressursi vabastamisel läheb serv tagasi nõudmise servaks
- Nõudmised peavad ette teada olema
- Kui graafis leidub tsükkel, siis on tegemist ohtliku olukorraga

Ressursigraafi algoritmi näide

- Ohutus olekus oleva süsteemi ressursigraaf

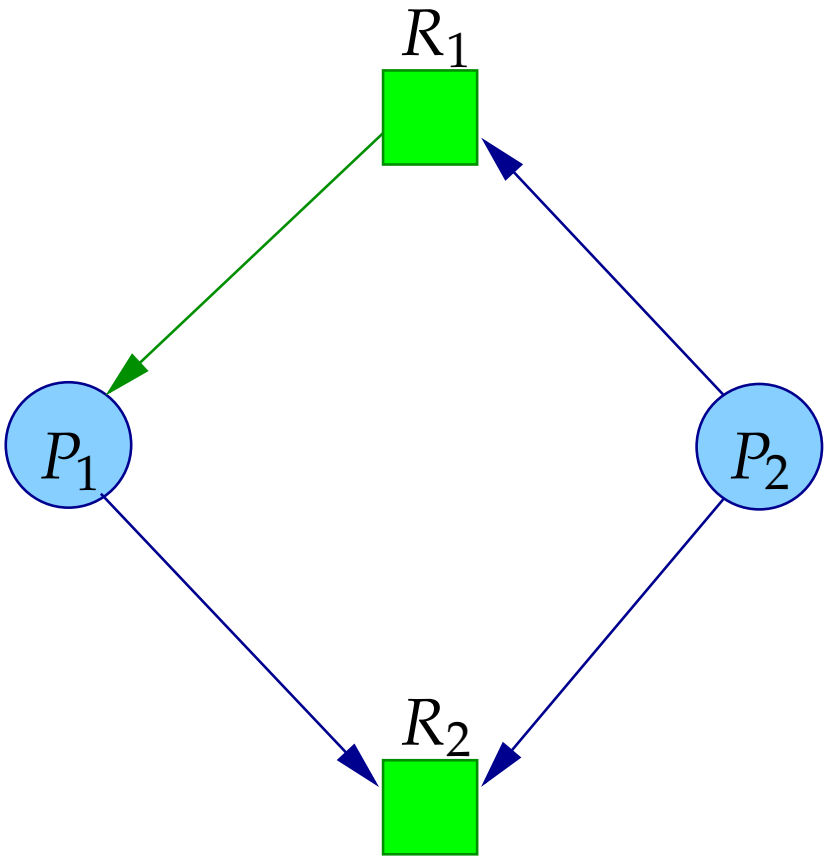

Ressursigraafi algoritmi näide

- Ressursi R_2 andmisel protsessile P_2 muutub olek ohtlikuks

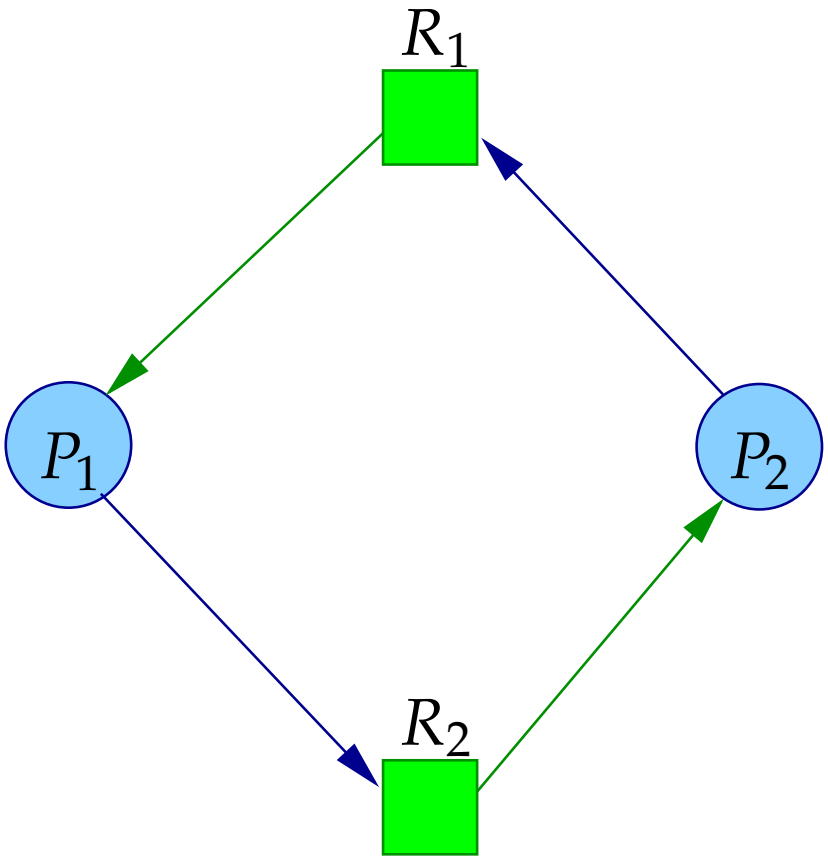

Pankuri algoritmi eeldused

- Igast ressursist on palju instantse
- Iga protsess peab ette ära ütlema maksimaalse ressursikasutuse
- Ressursi küsimisel võib protsess ootele jääda
- Ressursid tuleb lõpliku aja jooksul tagastada

Pankuri algoritmi andmed

- Olgu n protsesside arv ja m ressursitüüpide arv
- *Available* — vektor pikkusega m. $Available[j] = k$ tähendab, et ressurssi R_j on saadaval k tükki
- *Max* — $n \times m$ maatriks. $Max[i,j] = k$ tähendab, et P_i tohib küsida max. k instantsi ressursist R_j
- *Allocation* — $n \times m$ maatriks. Näitab, kui palju ressursse hetkel protsesside poolt kasutusel on
- *Need* — $n \times m$ maatriks. Näitab, kui palju ressursse on veel vaja töö lõpetamiseks

$$Need[i,j] = Max[i,j] - Allocation[i,j]$$

Pankuri algoritm ise

1. Olgu $Work$ ja $Finish$ vektorid pikkusega m ja n
2. Initsialiseerimine $Work = Available$, $Finish[i] = false$
3. Leiame sellise i, et kehtiksid
   - $Finish[i] = false$
   - $Need_i \leq Work$
4. Kui sellist i ei leidu, mine sammule 6
5. $Work = Work + Allocation_i$
   $Finish[i] = true$
   Mine sammule 3
6. Kui iga i korral $Finish[i] == true$, siis on süsteem ohutus olekus

Pankuri algoritm — ressursi küsimine

$Request_i$ — järgmisena küsitavate ressursside vektor

1. Kui $Request_i \leq Need_i$, siis mine sammule 2; vastasel juhul viga, kuna protsess on ületanud oma maksimaalsed ressursinõuded
2. Kui $Request_i \leq Available$, siis mine sammule 3; vastasel juhul peab protsess P_i ootama, kuna ressursid ei ole vabad
3. Simuleerime nõudmise täitmist:
   $Available = Available - Request_i$
   $Allocation_i = Allocation_i + Request_i$
   $Need_i = Need_i - Request_i$
   - Kui saadud olek on ohutu, siis anname protsessile need ressursid
   - Vastasel juhul peab protsess ootama ning muutujate vanad väärtused taastatakse

Tupikute avastamine (1)

- Laseme süsteemi tupikusse, avastame selle ja kõrvaldame tupiku
- Kui igast ressursitüübist on üks eksemplar, siis kasutame ootamisgraafi
- Ootamisgraaf on ressursigraafi modifikatsioon, kust
  - ressursitipud on välja jäetud ja
  - vastavad servad on kokku viidud
- Aegajalt otsime sellest graafist tsükleid (operatsiooni keerukus on n^2)

Ressursigraaf ja ootamisgraaf

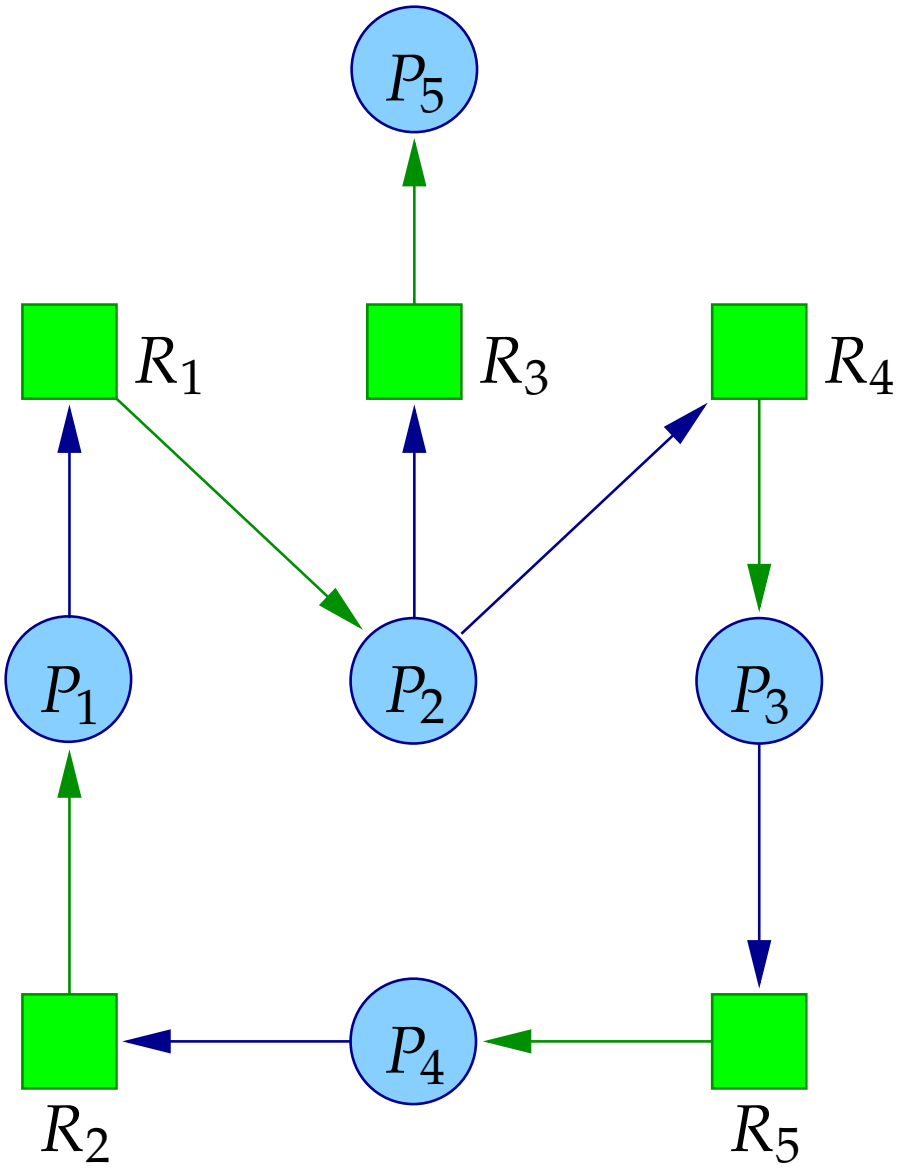

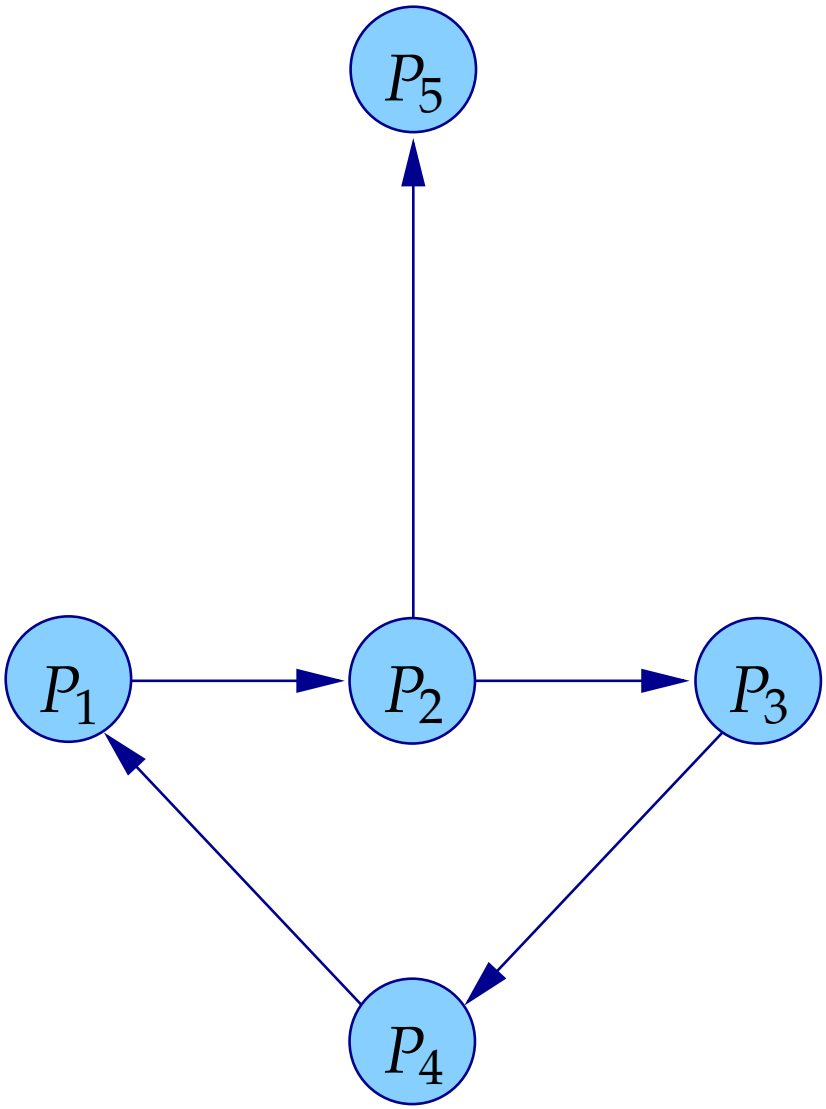

Tupikute avastamine (2)

Mitme ressursiinstantsi korral kasutame modifitseeritud pankuri algoritmi:

1. Olgu $Work$ ja $Finish$ vektorid pikkusega m ja n
2. Initsialiseerime $Work = Available$,
   $Finish[i] = (Allocation[i] == 0) \quad (i == 1..n)$
3. Leiame sellise i, mille korral
   - $Finish[i] = false$
   - $Need_i \leq Work$

   Kui sellist ei leidu, mine sammule 5
4. $Work = Work + Allocation_i$
   $Finish[i] = true$
   Mine sammule 3
5. Kui $Finish[i] == false$, siis on protsess P_i tupikus

Tupikute avastamine (3)

- See, millal ja kui tihti tupikute avastamise algoritme kasutada, sõltub
  - Tupikute tekkimise tõenäosusest
  - Tupikutest mõjutatavate protsesside arvust
- Liiga sagedane kasutamine on ebaefektiivne
- Liiga harv kasutamine teeb keeruliseks tupikut „põhjustava“ protsessi leidmise

Tupikutest taastumine

- Protsesside termineerimine
  - Tapame kõik tupikusse sattunud protsessid
    - väga kulukas
  - Tapame tupikus protsesse ükshaaval, kuni tupik on kõrvaldatud
    - samuti üsna kulukas
    - millises järjekorras tappa (prioriteedid, juba kulunud aeg, ressursside olemasolu/vajadus, . . .)?
- Ressursi väljatõrjumine
  - Valime ohvri — tupikus oleva protsessi, mille katkestamine on kõige „odavam“
  - Kerime tagasi — pöördume tagasi mõnda ohutusse olekusse ja taaskäivitame protsessi sealt
  - Näljutamine — võib juhtuda, et valime alati sama ohvri

Kombineeritud meetodid

- Grupeerime ressursid erinevatesse hierarhiliselt järjestatud klassidesse, näiteks
  - Põhimälu
  - Sekundaarne mälu
  - Protsessiressursid (I/O seadmed, failid, . . .)
- Klasside vahel kasutame tsüklilise ootamise ennetamist
- Iga klassi sees kasutame seal kõige paremini sobivat meetodit (s.t. kas ennetamist, vältimist või avastamist)