UNIX: folyamatok ütemezése

Mészáros Tamás
http://www.mit.bme.hu/~meszaros/

Budapesti Műszaki és Gazdaságtudományi Egyetem
Méréstechnika és Információs Rendszerek Tanszék

Az előző részben történt

- Mi a folyamat?
  - A feladatainkat megoldó program futás alatt álló példánya
- A folyamat viszonya a kernelhez
  - futási mód és kontextus
  - rendszerhívás interfész
  - kétféle futó állapot
  - az FK és F állapotok között kétirányú átmenet: preemptív ütemező
- A folyamat adminisztratív adatai
  - PID: folyamat azonosító (PPID: szülő azonosítója) *(Házi feladat: TID, TGID?)*
  - UID, GID: tulajdonos és csoport
  - aktuális állapot (F, FK, A, ...)
  - ütemezési információk
    - prioritás
    - nice érték

Feladatok ütemezése (ismétlés)

- Az ütemezés alapfeladata:
  kiválasztani a futásra kész feladatok közül a következő futót
- Alapfogalmak
  - preemptív ill kooperatív ütemező
  - mértékek: CPU kihasználtság, átbocsátó képesség, várakozási idő, körülfordulási idő, válaszidő
  - prioritás
  - statikus és dinamikus ütemezés
- A működés alapelve
  - a feladatokat sorokba (task/job queue) rendezzük (jellemzően FIFO)
  - az ütemező a sorokból választja ki a következő futó folyamatot
- Követelmények
  - minél kisebb erőforrásigény (overhead), komplexitás: O(1), O(log N)
  - optimalitás a mértékek valamilyen kombinációja szerint
  - determinisztikus, fair, elkerüli a kiéhezést, összeomlás elkerülése
  - speciális körülmények egyedi igényei (real-time, batch, multimédia, stb.)

A mai órán...

- A tradicionális UNIX ütemezés
  - tulajdonságai
  - működése kernel és felhasználói módban
  - prioritás számítása
  - részletes ütemezési algoritmus (felhasználói módban)
- Ütemezési mintapéldák
- Modern UNIX ütemezők
  - tulajdonságai, követelmények
  - a Solaris és a Linux ütemezők jellemzői

A tradicionális UNIX ütemezők jellemzése

- A UNIX ütemező preemptív, prioritásos és időosztásos

- Az ütemezés **prioritásos**
  - minden folyamat kap egy dinamikusan számított prioritás értéket
  - a legnagyobb prioritású folyamatot választja a futásra kész sorból

- Az ütemezés **időosztásos**
  - több folyamat konkurens futását támogatja
  - minden folyamat kap egy időszeletet, amíg futhat
  - az idő letelte után az azonos prioritásúak közül a következő fog futni

- **A felhasználói és kernel mód ütemezése eltérő**
  - felhasználói módban: preemptív és időosztásos, időben változó prioritás
  - kernel módban: nem preemptív, nincs időosztás, rögzített prioritás

Az ütemezés adatstruktúrái

- A prioritás egész szám, pl. 0-127 közötti értéket vehet fel
  - a 0 a legmagasabb prioritás, a 127 a legkisebb
  - 0-49: kernel prioritási szintek 50-127: felhasználói szintek
- Az ütemező a folyamatokat prioritásuk szerint 32 FIFO sorba rendezi

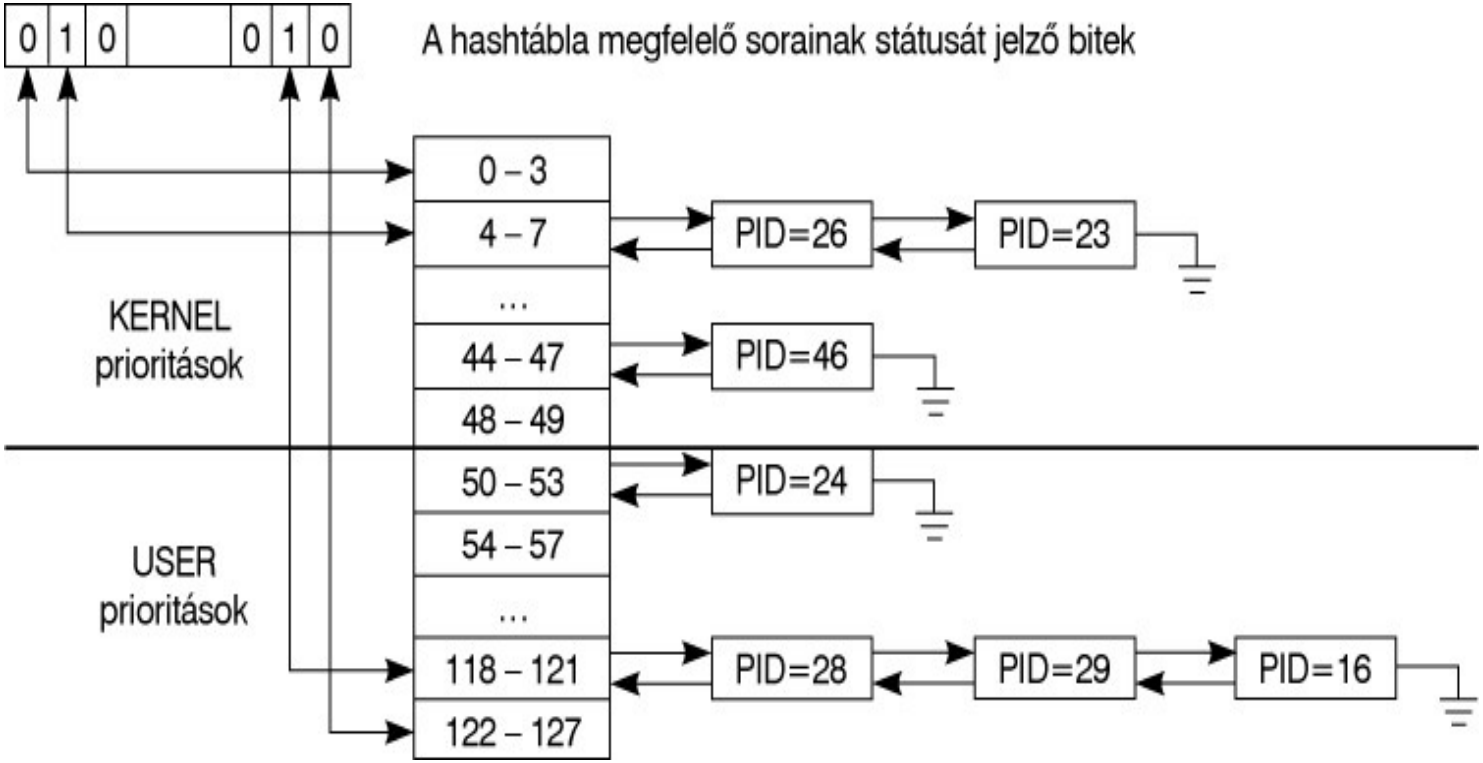

Ütemezés kernel módban

- A kernel módú ütemezés tulajdonságai:
  - a prioritás rögzített értékű
  - tradicionálisan nem preemptív, így könnyű a konzisztencia biztosítása
  - modern UNIX-okban részben (adott pontokon) vagy teljesen preemptív

- A prioritás nem függ attól, hogy
  - mennyi volt a folyamat prioritása felhasználói módban
  - mennyi processzor időt kapott korábban

- A kernel módú prioritás meghatározása
  - A prioritást a folyamat elalvásának az oka határozza meg.
    Ez az ún. **alvási prioritás** (sleep priority).
  - A folyamat felébredése után ez fogja meghatározni a prioritását.
  - Az alvási prioritás az alvás okához kötött, pl.:

    20 diszk I/O-ra vár

    28 inputra vár a karakteres terminálról

Ütemezés felhasználói módban

- Felhasználói módban a számított prioritás az ütemezés alapja
  - mindig a legnagyobb prioritású folyamatot ütemezi be a kernel
  - megnézi a hash táblát, és kiválasztja a legmagasabb futási szintet, ahol van folyamat
  - ha magasabb, mint a futó folyamat szintje, akkor átütemez (prioritásos)
  - ha azonos a futó folyamat szintjével, és letelt a futó folyamat időszelete, akkor szintén átütemez (időosztásos)

- Az ütemezési tevékenység idő szerint rendezve
  - minden óraciklusban

    Van-e magasabb szinten folyamat? Ha igen, akkor átütemezés.

    A legmagasabb, folyamatot tartalmazó futási szint sorban első folyamata fog futni.
  - minden időszelet végén (10 óraciklus)

    Van-e másik folyamat az éppen futó folyamat prioritásának megfelelő futási szinten? Ha igen, akkor átütemezés.

    Az adott szint első folyamata fog futni. A premptált folyamat a sor végére kerül.

    Azaz az időosztásos ütemezési rész **Round-Robin algoritmus** szerinti.

Az ütemezés adatai (a prioritás kiszámításhoz)

- A kernel a következő adatokkal írja le a folyamatokat
  - `p_pri` a folyamat aktuális prioritása
  - `p_usrpri` a folyamat felhasználói módban érvényes prioritása
  - `p_cpu` a korábbi CPU használat mértéke
  - `p_nice` a felhasználó által adott prioritás módosító érték

- Kernel módba váltáskor a prioritás értéke „elmentődik” a `p_usrpri` változóba annak érdekében, hogy felhasználói módba visszalépéskor visszaállítható legyen

- A `p_cpu` érték azt fejezi ki, hogy a folyamat az elmúlt időszakban mennyi processzor időt kapott. Ez csökkenteni fogja a prioritását, azaz biztosítható a fair ütemezés.

A prioritás számítása felhasználói módban

- Minden óraciklusban a futó folyamatra növeli a p_cpu értékét

```
p_pcu++
```

- Minden 100. óraciklusban a kernel kiszámítja a prioritás értékét
  - minden folyamatnál „öregíti” a p_cpu értéket

```
p_cpu = p_cpu * KF
```

KF: korrekciós faktor „felejtés”

  - kiszámolja a prioritást

```
p_pri = P_USER  +  p_cpu / 4  +  2 * p_nice
```

  - A P_USER konstans, a kernel és a felhasználói módot választja szét

```
P_USER = 50
```

- A korrekciós faktor számítása
  - SVR3: `KF = 1/2` (Mi ezzel a baj?)
  - 4.3 BSD: a futásra kész folyamatok átlagos számától (`load_avg`) függ:

```
KF = 2 * load_avg  /  (2 * load_avg + 1)
```

A felhasználói módú ütemezés összefoglalója

- Minden óraütésnél
  - Ha van magasabb prioritási sorban folyamat, akkor átütemezés
  - A futó folyamat p_cpu értékének növelése (csökkenni fog a prioritása)
- Minden 10. óraütésnél
  - Round-Robin ütemezés a legmagasabb (felhasználói) futási szinten levő folyamatok között
- Minden 100. óraütésnél
  - a korrekciós faktor kiszámítása az elmúlt 100 ciklus átlagos terhelése alapján
  - a p_cpu „öregítése”
  - a prioritás újraszámolása
  - szükség szerint átütemezés

Ütemezési mintapéldák

- Három folyamat, Round-Robin ütemezés nélkül
- Ütemezés Round-Robin ütemezzéssel együtt

Lásd: utemezes_peldak.xls

A tradicionális UNIX ütemezés értékelése

+ Egyszerű és hatékony.
+ Általános célú időosztásos rendszerben megfelelő.
+ Jól kezeli az interaktív és batch típusú folyamatok keverékét.
+ Elkerüli az éhezést.
+ Jól támogatja az I/O műveleteket végrehajtó folyamatokat.

– Nem skálázódik jól: ha sok a folyamat, akkor sok a számítás.
– Nem lehet folyamat (csoportok) számára CPU-t garantálni.
– Nem lehet a folyamatokat igényeik szerint eltérően ütemezni.
– Nincs garancia a válaszidőre.
– A többprocesszoros támogatás, NUMA nem kidolgozott.
– A kernel nem preemptív:

  Ha egy folyamat sokáig fut kernel módban, akkor feltartja az egész rendszert.

  prioritás inverzió: egy alacsonyabb prioritású folyamat feltart egy nála magasabb prioritású folyamatot.

Modern UNIX ütemezők szempontjai

- Új ütemezési osztályok
  - speciális alkalmazási igények: multimédia, beágyazott, stb.
  - „fair share”: az erőforrások tervezhető elosztása (pl. Linux *cgroups*)
  - a kernelek is egyre több saját folyamatot (szálat) futtatnak
  - batch, real-time, kernel és interaktív folyamatok keveréke fut egy időben
  - moduláris ütemező rendszer szükséges: bővíthető keretrendszer
- Kernel megszakíthatóság
  - a tradicionális UNIX kernel nem preemptív (szűk keresztmetszet)
  - a többprocesszoros (többmagos) ütemezéshez elengedhetetlen
- Az ütemező erőforrásigénye (teljesítménye)
  - az ütemezés egyre összetettebb feladat (több processzor, többféle sor)
  - nem lenne jó az ütemezésre pazarolni a processzoridőt
  - az ütemezési algoritmus komplexitása lineáris, de inkább *O(1)* legyen
- Szálak kezelése (folyamatokat vagy szálakat ütemezünk?)
  - szálak számának növekedésével nő az ütemező terhelése (Java VM)
  - a szálak kerültek előtérbe – ennek megfelelő ütemező kell

A Solaris ütemező tulajdonságai

- Alapvető tulajdonságok
  - az ütemezés szálalapú
  - a kernel is preemptív
  - támogatja a többprocesszoros rendszereket és a virtualizációt (zónák)

- Többféle ütemezési osztály
  - Időosztásos (TS): az ütemezés alapja az, hogy ki mennyit várt/futott
  - Interaktív (IA): azonos a fentivel, de az éppen aktív ablakhoz tartozó folyamat kiemelése
  - Fix prioritás (FX): állandó prioritású folyamatok
  - Fair share (FSS): CPU erőforrások folyamatcsoportokhoz rendelése
  - Real-time (RT): a legkisebb késleltetést biztosító legmagasabb szint
  - Kernel szálak (SYS): az RT szint kivételével mindennél magasabb szint

A Solaris ütemezési szintjei

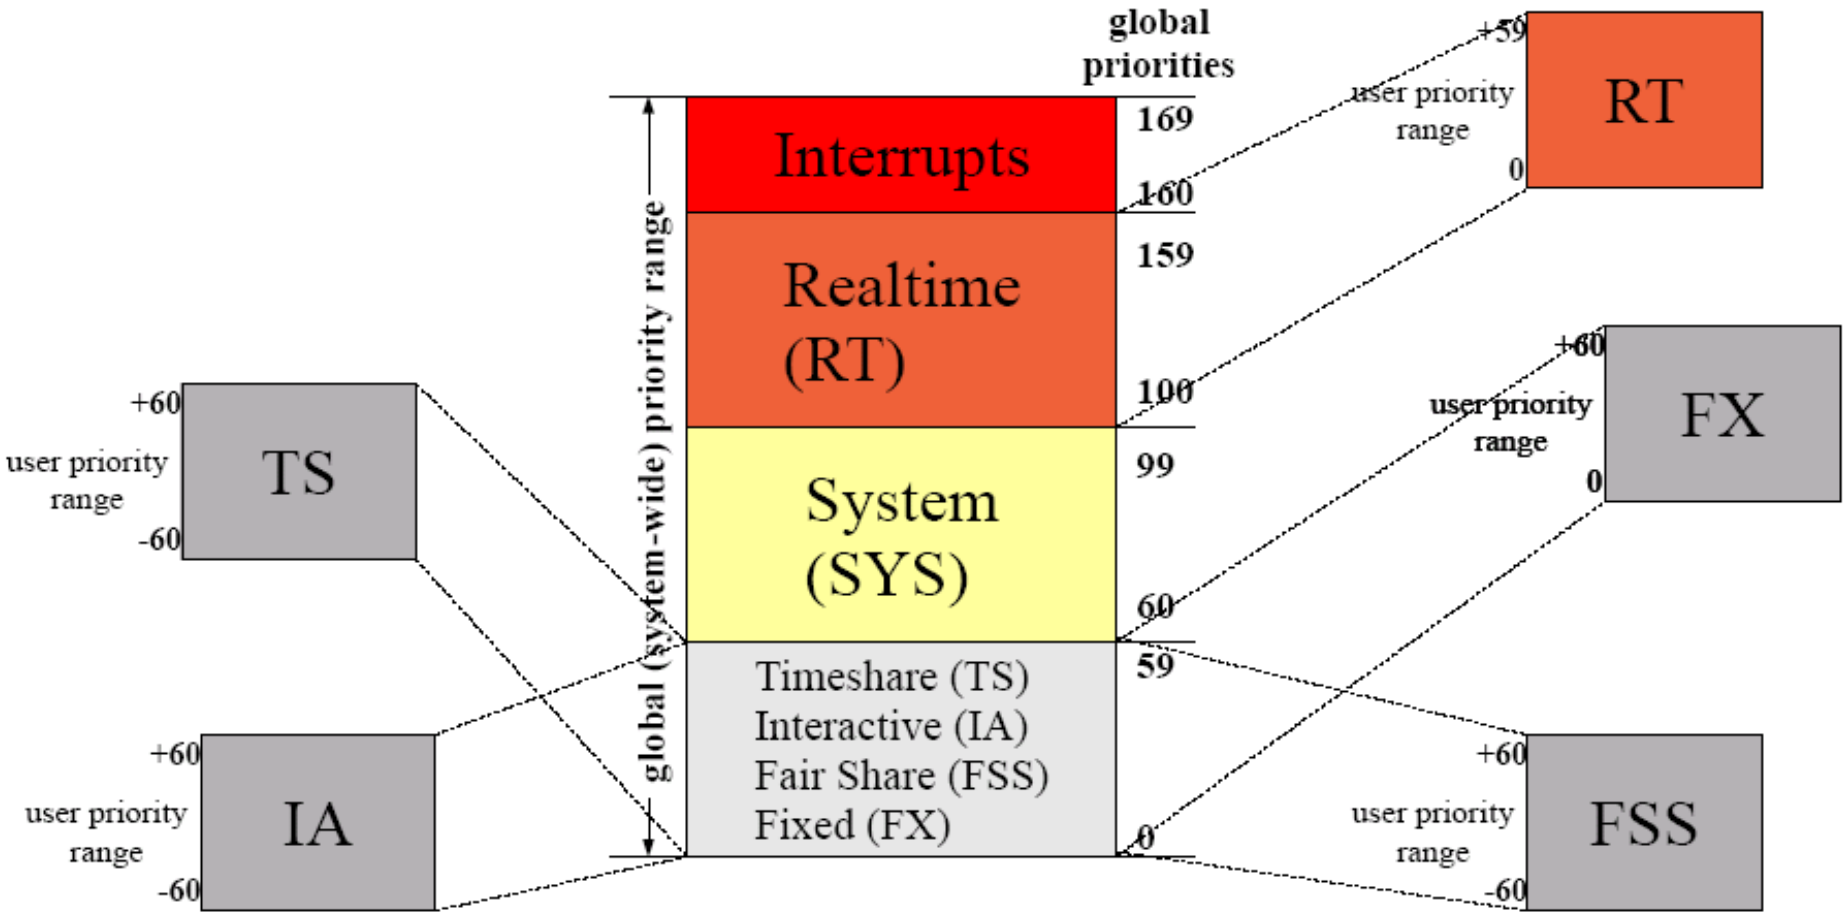

Örökölt prioritások (Solaris)

- A prioritás inverzió problémája (kék nyíl: vár, piros nyíl: foglal)
- Megoldás: prioritás emelés, avagy örökölt prioritások

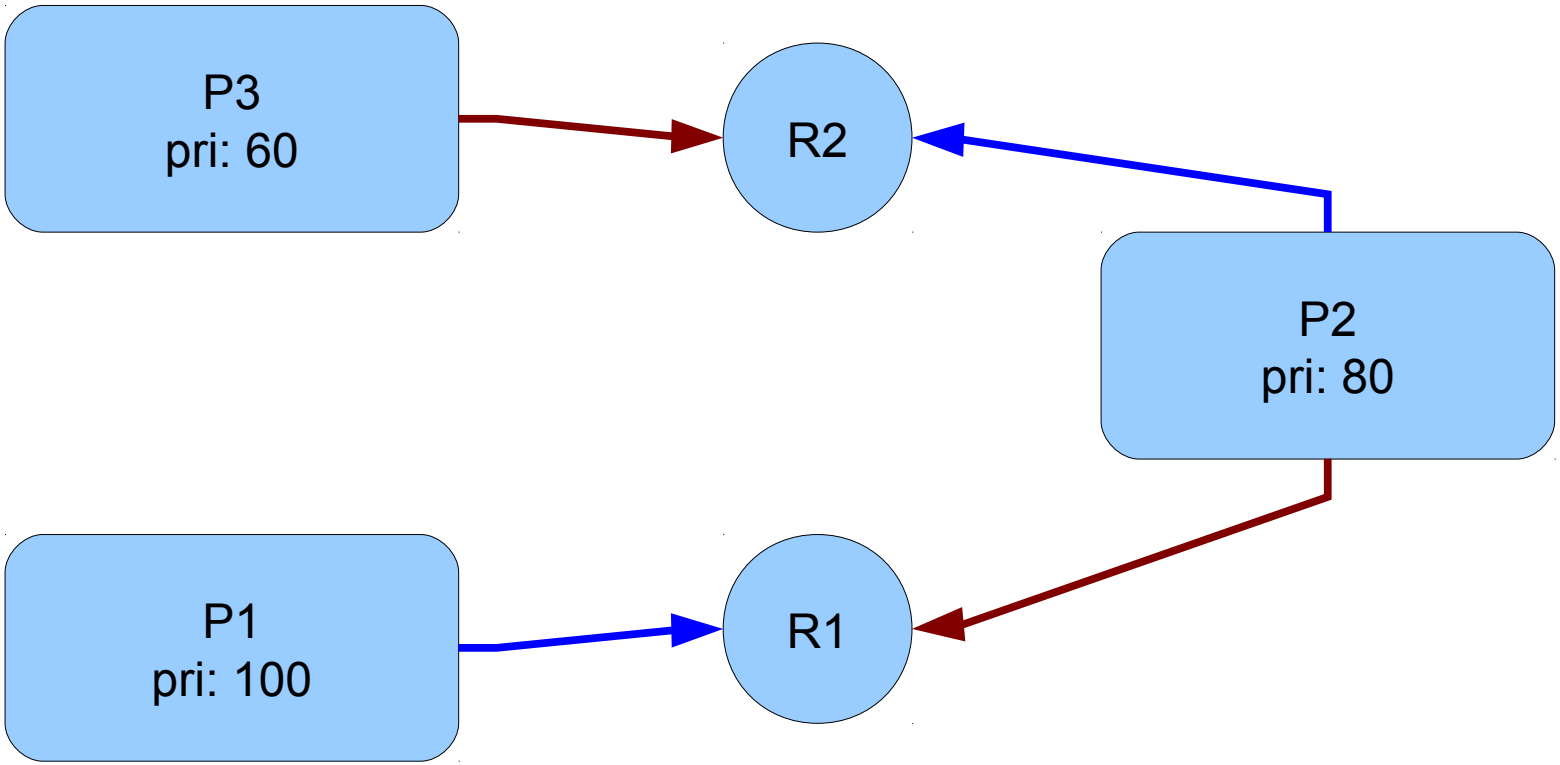

Linux ütemezők története, tulajdonságai

- Az első változatok (v2 előtt) a tradicionális ütemezőre épültek
- 2.4-es kernel előtt
  - ütemezési osztályok: real-time, nem-preemptív, normál
  - összetettebb ütemezés, amely O(N) komplexitású
  - még egyetlen ütemezési sor (nincs SMP támogatás)
  - nem preemptív kernel
- kernel v2.6
  - O(1) ütemező, jobban skálázható
  - processzoronkénti futási sorok (jobb SMP támogatás)
  - I/O és CPU terhelésű folyamatok heurisztikus szétválasztása
    - a futási és alvási idők összevetése alapján (a számítás elég sok idő)
    - előbbieket előnyben részesíti
- 2.6.23 kerneltől: CFS (Completely Fair Scheduler)
  - Con Kolivas egyes ütemezési ötleteit felhasználva Molnár Ingo munkája
  - a cpu idő biztosításának kiegyensúlyozása egy speciális adatstruktúra segítségével („időben rendezett piros-fekete fa”)

Linux: ütemezési információk (gyakorlat)

- Információgyűjtés a *proc* virtuális fájlrendszer segítségével
  - /proc/cpuinfo – a rendszerben elérhető processzor(ok) jellemzői
  - /proc/stat – a processzorok és az ütemező jellemzői
  - /proc/loadavg – átlagos terheltség (az elmúlt 1, 5, 15 percben)
  - /proc/sys/kernel/sched* – a kernel ütemezőjével kapcsolatos adatok
  - /proc/<PID>/status – State: a folyamat állapota, Cpus_allowed, ...
  - /proc/<PID>/sched – ütemezési adatok

- Mit csinál a folyamatom (számítógépem)?
  - Érdekes olvasmány: Peeking into Linux kernel-land using /proc filesystem

    Egy egyszerű find parancs lassú működésének az okát kutatta a már ismert `ps, strace, /proc/PID/...` használatával (adatbázis szerver alatt).
  - A különböző komponensek (cache, memória, diszk, hálózat) összevetése

    What Your Computer Does While You Wait

Linux CFS

- A korábbi *O(1)* ütemezőt felváltó *O(log n)* ütemező
- Sor (lista) helyett egy speciális fa struktúrában tárolja a folyamatokat *red-black tree*: önkiegyensúlyozó bináris keresési fa `<linux/rbtree.h>`
  - a bináris fa miatt *O(log n)* komplexitású a keresés
  - a törlés és beszúrás véges idejű művelet
- A prioritás számításának alapjai
  - virtuálisan futó folyamatok száma (`nr_running`)
  - virtuális futási idő (`vruntime`): a folyamat futási ideje (rbtree index)
- Alapvető műveletek
  - enqueue_task: új folyamat érkezik (nr_running++)
  - dequeue_task: már nem futásra kész (nr_running--)
  - pick_next_task: ki fog futni legközelebb

Összefoglalás

- A klasszikus UNIX ütemező
  - felhasználói módban: prioritásos, időosztásos, preemptív
    - többszintű ütemezési tevékenység
    - azonos prioritási szinten round-robin ütemezés (időosztás)
    - a prioritás alapja a korábbi CPU használat és a *nice* érték
  - kernel módban
    - rögzített prioritás, alapja az ún. alvási prioritás
    - nem preemptív
  - egyszerű, kerüli az éhezést, de rosszul skálázható és nem támogat sok mai alkalmazási igényt (valósidejű rendszerek, multimédia, stb.)

- Modern UNIX ütemezők
  - moduláris felépítésű ütemező rendszer
  - több ütemezési osztály az alkalmazási igényeknek megfelelően
  - többprocesszoros rendszerek támogatása
  - jobb erőforrás-allokáció
  - szálak ütemezése