HÁLÓZATI RENDSZEREK ÉS SZOLGÁLTATÁSOK TANSZÉK

MŰEGYETEM 1782

Budapest,
2024.04.29.

SZÁMÍTÓGÉP ARCHITEKTÚRÁK

Elágazásbecslés

Horváth Gábor, Belső Zoltán

BME Hálózati Rendszerek és Szolgáltatások Tanszék
ghorvath@hit.bme.hu, belso@hit.bme.hu

PROCEDURÁLIS EGYMÁSRAHATÁSOK

- Procedurális egymásrahatás:
  - Ugrások okozzák
  - Megtörik az utasításfolyam szekvenciális viselkedését
- Mi a gond?
  - Pl. feltételes ugrás esetén tudni kell:
    - Az elágazás ***kimenetelét*** (ugrik-e, vagy sem)
    - Ugrás esetén az ***ugrási címet*** (hová ugrik)
  - IF dolga: utasítások betöltése
    - Nincs ideje feltételkiértékelésre **és** címszámításra!
    - Egy tipphez van ideje
      - Ha bejön, annak örül
      - Ha nem:
        - A tévedésből elkezdett utasításokat érvényteleníteni kell
        - Legközelebb tanul a hibájából

AZ ELÁGAZÁSBECSLÉS FELADATA

- Szekvenciális futást megtörő utasítások:
  - **Feltétel nélküli ugrás:**
    - Direkt: `JUMP -28`
    - Indirekt: `JUMP R1`
    - `-28` vagy `R1`: ugrási cím
  - **Feltételes ugrás:**
    - Direkt: `JUMP -28 IF R2>0`
    - Indirekt: `JUMP R1 IF R2>0`
    - `R2>0`: ugrási feltétel
    - `-28` vagy `R1`: ugrási cím
  - **Szubrutinhívás:**
    - Direkt: `CALL -28`
    - Indirekt: `CALL R1`
    - Visszatérés: `RET`, ugrási cím a veremből
- Az elágazásbecslés feladata:
  - Kimenetel becslése, ha van ugrási feltétel
  - Ugrási cím becslése

AZ ELÁGAZÁSBECSLÉS JELENTŐSÉGE

- Mit nyerünk, ha bejön a becslés?
  - Fennakadás nélkül zajlik az utasítások betöltése
- Mit vesztünk, ha rossz a becslés?
  - Minél később derül ki a rossz döntés, annál több időt fecsérel a processzor tévedésből betöltött utasításokra
  - Minél hosszabb a pipeline, annál nagyobb a veszteség!
  - Példa (Intel Core i7 Nehalem):
    - 4 utas szuperskalár processzor
    - A belépéstől számítva 17 ciklus múlva számolja ki a tényleges ugrási címet és értékeli ki az ugrási feltételt
    - Tfh. minden negyedik utasítás feltételes ugrás
    - Tfh. az elágazásbecslő pontossága 67%
    - Tfh. más egymásrahatás nincs

AZ ELÁGAZÁSBECSLÉS JELENTŐSÉGE

- A példa folytatása:
  - 4 utas szuperskalár: órajelciklusonként 4 utasítás az átvitel
    → Ideális eset: átlag **0.25 órajelciklus/utasítás**
  - Utasítások negyede ugrás, minden ugrás 0.33 valószínűséggel 17 ciklusnyi extra késleltetést (kidobott időt) jelent
  - Átvitel: 0.25 + 0.25*0.33*17 = **1.65 ciklus/utasítás**
  - **6.6x** gyorsabb lenne a processzor, ha tökéletes lenne az elágazásbecslője!!!

AZ ELÁGAZÁSBECSLÉS JELENTŐSSÉGE

- A rossz döntés okozta kiesett ciklusok száma:

CPU	Kiesett ciklusok száma
Intel Pentium I MMX	4-5
Intel Pentium 4	átlagosan 45(!)
Intel Core2	15
Intel Core i7 Skylake	16.5
Intel Atom	13
AMD K8 és K10	12
AMD Ryzen	19
Via Nano	16
ARM Cortex A53	7
ARM Cortex A72	15

Ugrási feltétel kimenetelének becslése

MI IS A FELADAT?

- Ismert (lehet): az ugró utasítás kimenetelei a múltban
- Feladat: mi lesz a következő kimenetel?
  - **1111111?**
  - **1111110110111011111?**
  - **110011001100 11?**
  - **111111111100000000000?**

- Elvárások:
  - Legyen a becslő *gyors*
  - Legyen a becslő *egyszerű*
  - Legyen nagy a találati aránya

EGYSZERŰ ÁLLAPOTGÉP ALAPÚ MÓDSZER

- Minden ugró utasításhoz egy állapotgépet rendelünk
- Ez tárolja, mennyire szeret ugrani
- Ha a közepesnél jobban szeret, akkor ugrásra tippelünk
- Táblázat frissítése: a **tényleges** bekövetkezés ismeretében

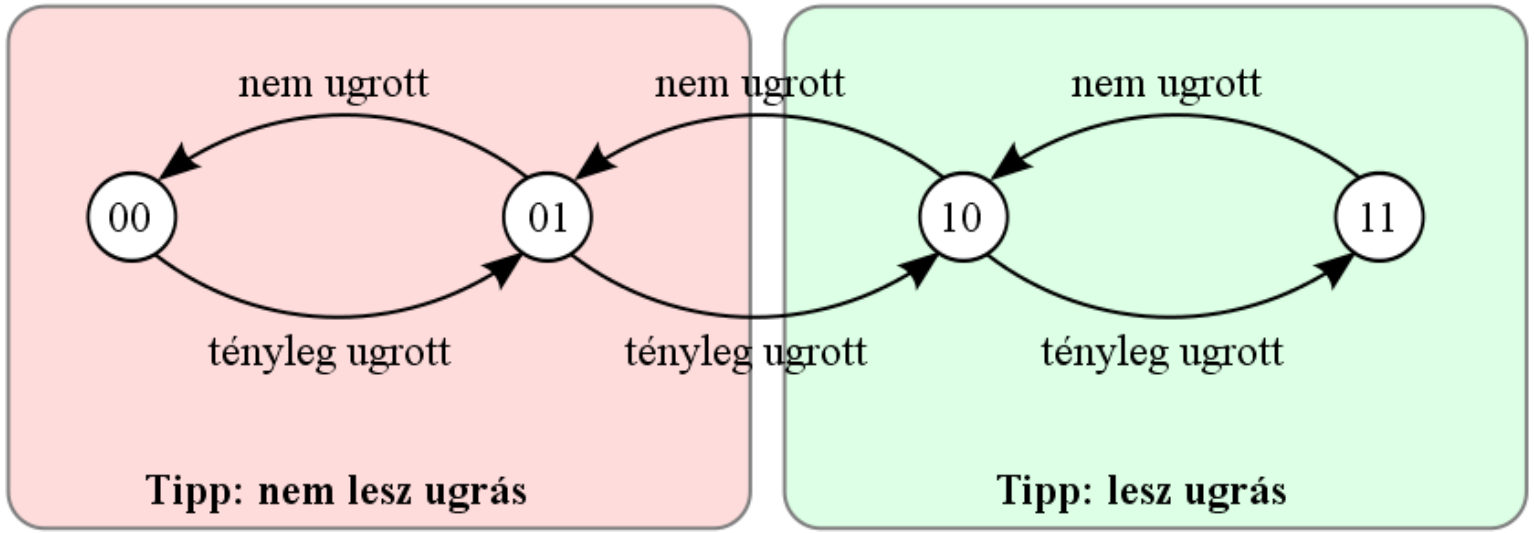

EGYSZERŰ ÁLLAPOTGÉP ALAPÚ MÓDSZER

- Hatékonyságvizsgálat:

```
for (i=0; i<m; i++) {
    for (j=0; j<n; j++) {
        ...
  }
}
```

- Belső ciklus becslését vizsgáljuk: n*m döntés
- 1 bites számlálóval: 2*m rossz becslés
- 2 bites számlálóval: m rossz becslés

EGYSZERŰ ÁLLAPOTGÉP ALAPÚ MÓDSZER

- Hol tároljuk az állapotot?
  - Valamilyen cache szerű szervezéssel
    - 32 bit-es tag, 2 bites adat → nem éri meg!
  - Utasítás cache blokkjaiban az utasítások mellett → AMD
  - Külön táblázatban: **PHT** (Pattern History Table)
    - Pl: Pentium 1

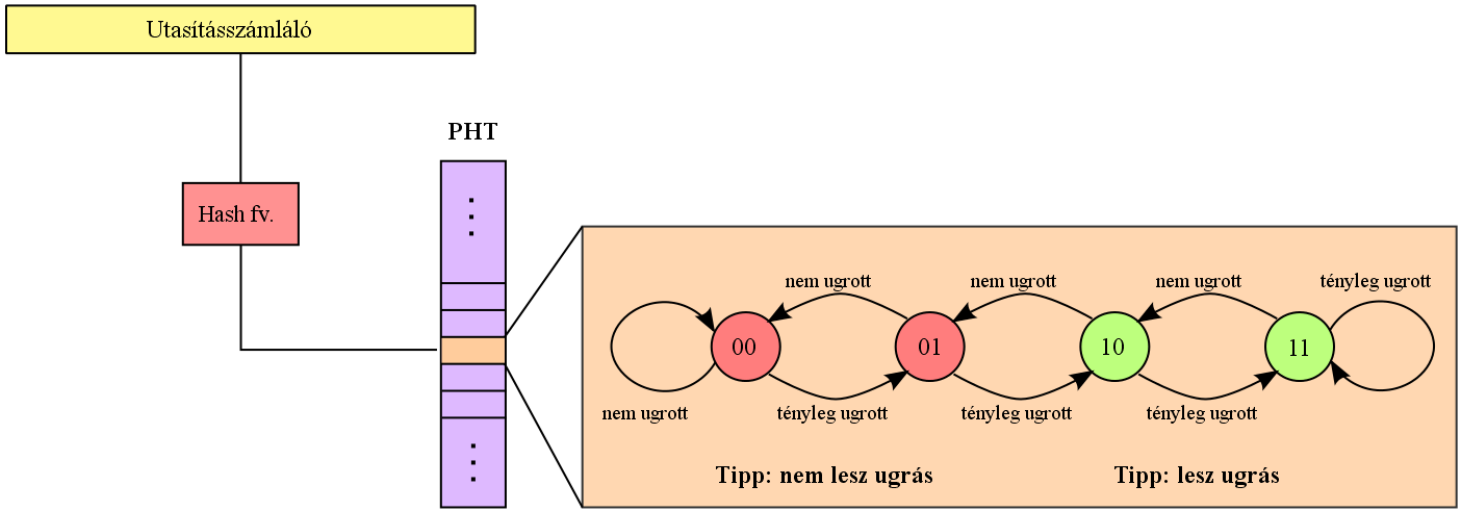

KORRELÁCIÓ FIGYELEMBE VÉTELE

- Az ugró utasítások kimenetele gyakran függ más ugró utasítások kimenetelétől
- Példa:

```
if (a==2)
    a = 0;
if (b==2)
    b = 0;
if (a!=b) {
    ...
}
```

- Ha az első kettő igaz volt, a harmadik nem lesz igaz!
- Jó lenne kihasználni

KORRELÁCIÓ FIGYELEMBE VÉTELE

- A trükk: tároljuk az egymást követő utasítások kimeneteleit egy shift regiszterben → **globális előzmény regiszter** (Global Branch History Register, GBHR)
  - Ha feltételes ugrás történik, a *tényleges* kimenetele jobbról lép be (0 vagy 1)
  - Egy k bites GBHR az utolsó k ugrás kimenetelét tárolja
  - A PHT-t ezzel indexeljük

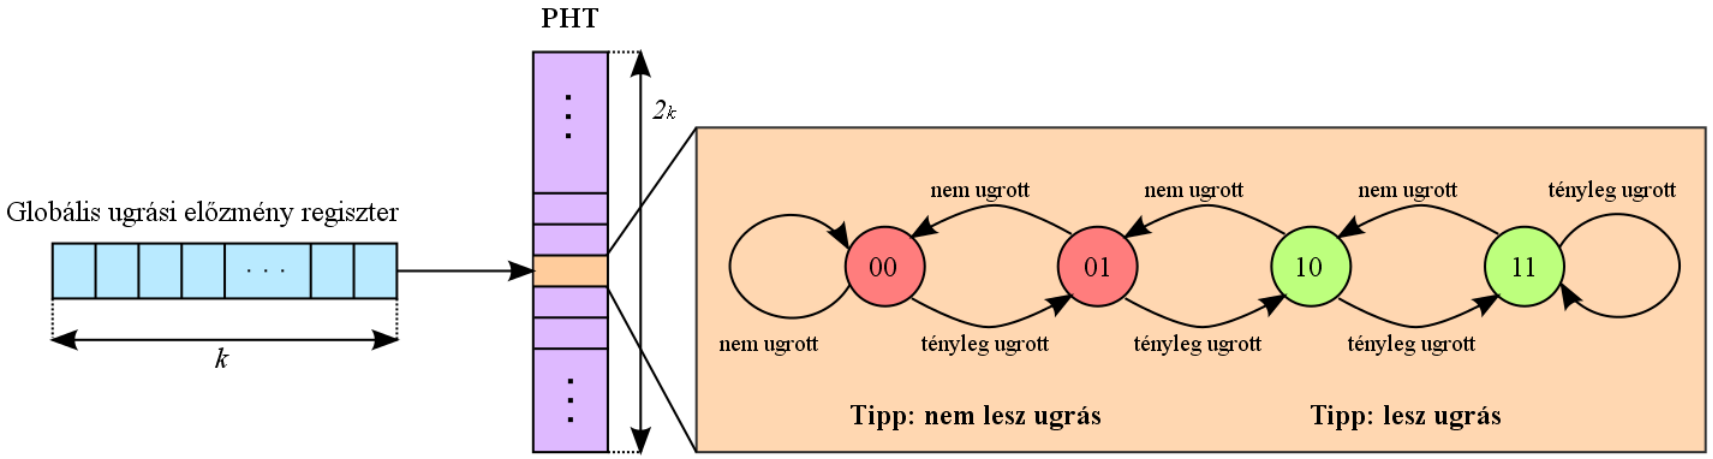

KOMBINÁLT PREDIKTOROK

- Tanultunk egyszerű állapotgép alapú becslést
  - Utasításra lokális döntést hoznak
- Tanultunk korrelációt figyelembe vevő módszert
  - Kizárólag a globális előzmények alapján dönt
- Miért ne kombináljuk a kettőt?

A GSHARE PREDIKTOR

- Kombinálja a lokális és globális információkat
  - Lokális döntés: megnézzük, hogy az adott utasításhoz mit jósol a PHT
  - Globális döntés: megnézzük, hogy az előzmények mellett mit jósol a PHT
  - Kombináljuk a kettőt: PC XOR GBHR

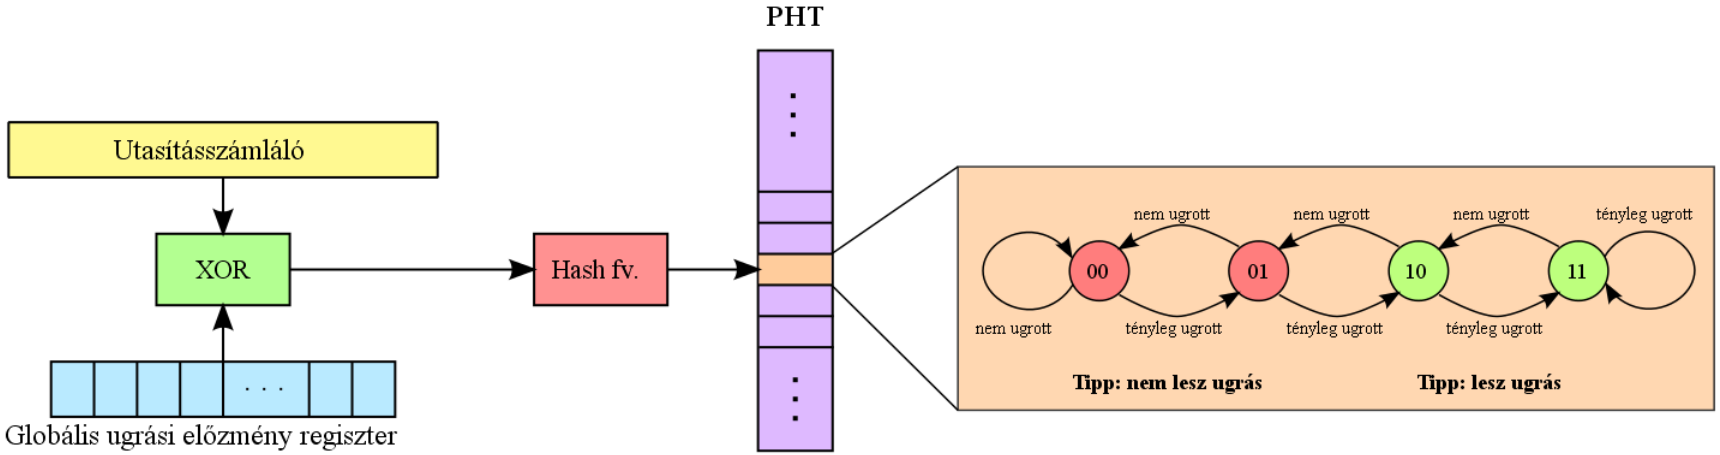

- Nagyon egyszerű, és meglepően pontos!
- SPARC, POWER4, XBox 360, AMD Athlon,
  egy kicsit módosított változata az ARM Cortex A8-ban

AZ AGREE PREDIKTOR

- Lokális eljárás: merre „húz” az adott ugró utasítás
- Globális eljárás: az ugrás a tipikus irányba fog-e megvalósulni

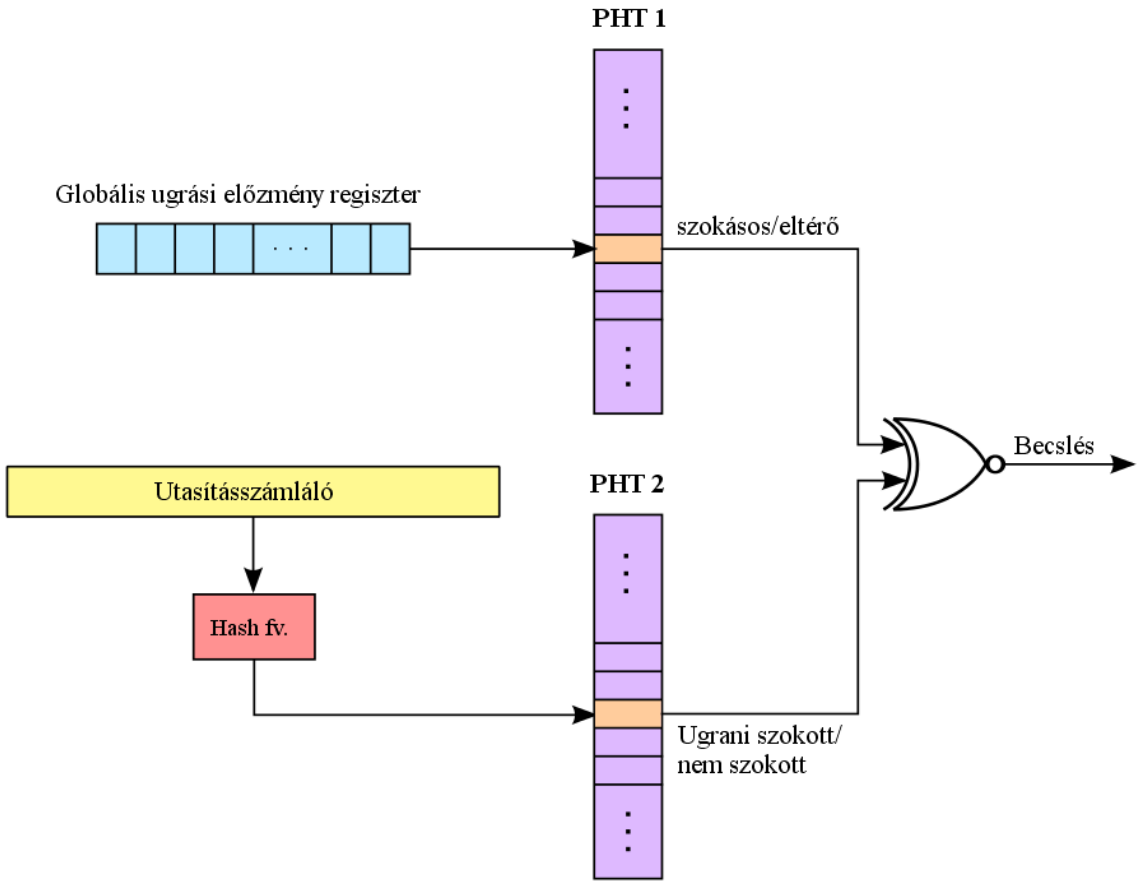

"TOURNAMENT" PREDIKTOROK

- Két prediktor működik egyszerre, egy lokális és egy globális
- Mindig csak az egyik dönt: az, amelyik mostanában pontosabban becsült
- Ezt egy állapotgép követi, hogy mostanában melyik vált be jobban

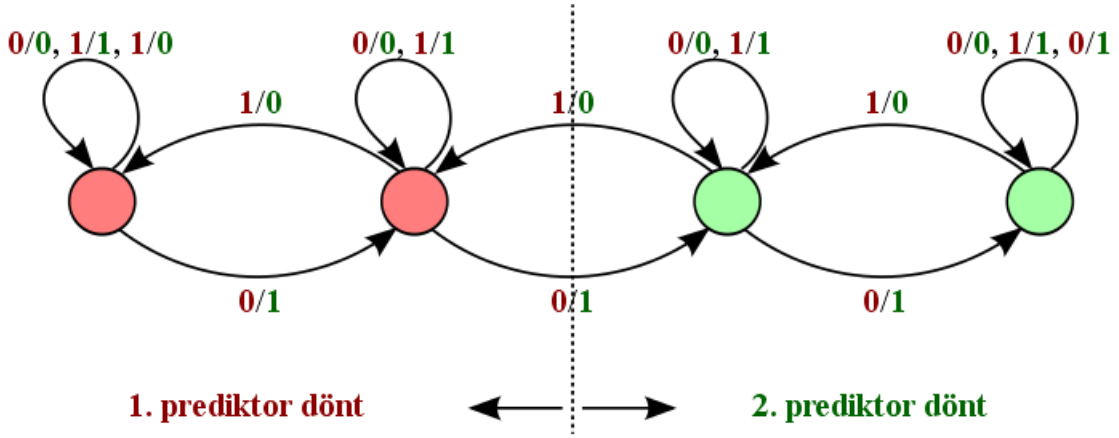

Ugrási cím becslése

UGRÁSI CÍM BECSLÉSE

- Honnan kell betölteni a következő utasítást?
  - Ezt az IF-nek sürgősen tudni kell!
  - Feltételes és feltétel nélküli ugrásoknál egyaránt kérdés.
- Kiolvassuk egy speciális "***ugrási cím buffer***"-ból
  (BTB: Branch Target Buffer)

  → Könnyebb/gyorsabb innen kiolvasni, mint kiszámolni
  - A BTB mezői:
    - tag: az ugró utasítás címe
    - várható ugrási célcím
  - Szervezése:
    - Valamilyen cache szervezés, pl. 4 utas asszociatív
    - Tartalommenedzsment: LRU
  - Téves becsléskor korrigáljuk a régi értéket

AZ UGRÁSI CÍM BUFFER

- Ha már egyszer minden egyes ugró utasításhoz van bejegyzése, mást is tárolhatunk benne:
  - Az ugrási hajlandóságot
  - Az utasítás korábbi kimeneteleit (előzmény)
- Például:

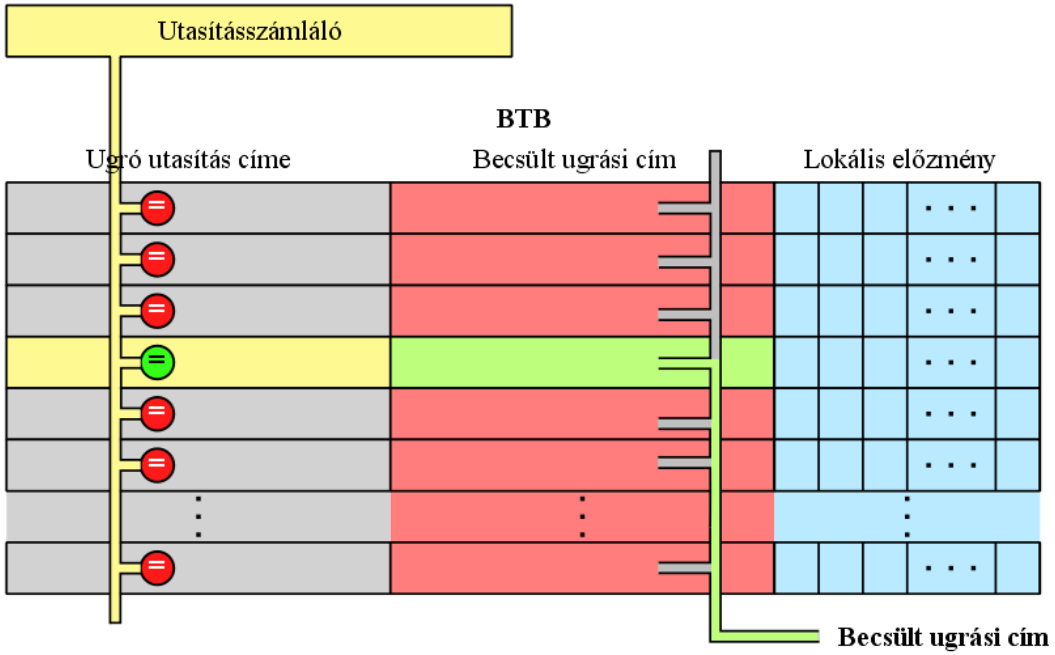

SZUBRUTINHÍVÁSBÓL VISSZATÉRÉSI CÍM BECSLÉSE

- A **RET** speciális ugró utasítás
  - Ugrási cím a lassú memóriában van (stack)
- Becsléshez hatékony adatszerkezet: **return stack**
  - A CPU-ban található
  - Nagy sebesség, kis kapacitás
  - Szubrutinhíváskor a visszatérési cím
    - az igazi (lassú) stack tetejére kerül
    - ...a return stack tetejére is bekerül!
  - Visszatéréskor:
    - Nem kell megvárni az igazi lassú stack-et!
    - A return stack ciklusidőn belül megmondja a címet
  - Addig hatékony, amíg nem telik meg
    - Ha nincs túl sok egymásba ágyazott függvény hívás

TIPIKUS UGRÁSI CÍM BUFFER PARAMÉTEREK

Processzor	BTB bej.-ek száma	BTB szervezése	Return stack
Intel Pentium I MMX	256	4 utas asszoc.	nincs
Intel Pentium 4	4096	val. 8 utas asszoc.	nincs
Intel Core2 (ciklusokhoz)	128	2 utas asszoc.	16
Intel Core2 (indir. ugr.)	8192	4 utas asszoc.	
Intel Core2 (egyéb ugr.)	2048	4 utas asszoc.	
Intel Atom	128	4 utas asszoc.	8
AMD Steamroller	L1: 512, L2: 10240	L1: 4 utas, L2: 5 utas	24
AMD Ryzen	8/256/4096	?	31
Via Nano	4096	4 utas asszoc.	Nagyon mély
ARM Cortex A8/A9	512	2 utas asszoc.	8

NEHÉZSÉGEK

- Hogy lehet kibabrálni az ugrási cím becslővel?
- Ugrabugráljunk kiszámíthatatlanul!
  - Pl. heterogén kollekció bejárása
    és virtuális függvények hívása c++-ban
  - Függvénypointereket tartalmazó tömb
- Lehetséges megoldás:
  - A gond az, hogy az ugrási cím buffer csak egyetlen ugrási címet tud tárolni
  - Tároljon többet! A globális előzmények függvényében dönt a becslő, hogy melyik ugrási címet dobja be tippként
  - Pl.: ARM Cortex A15, Intel Core Nehalem, AMD Ryzen, stb.

Elágazásbecslés-tudatos programozás

ELÁGAZÁSOK SZÁMÁNAK CSÖKKENTÉSE

- 1. példa:

```
for (int i=0; i<N; i++)
    if (data[i] > 500)
        sum += data[i];
```

- A feltétel kiváltható egy logikai kifejezéssel
  - `data[i]>500` ↔ `(data[i]-501) >= 0`
  - `data[i]-501` jobbra shiftelve (aritmetikai shift!):
    - `000...0` vagy `111...1`
  - Maszkoljuk vele az összeadást!
- Elágazásmentesített kód:

```
for (int i=0; i<N; i++) {
    int t = (data[i]-501) >> 31;
    sum += ~t & data[i];
}
```

ELÁGAZÁSOK SZÁMÁNAK CSÖKKENTÉSE

- 2. példa:

```
for (int i=0; i<N; i++)
    if (min<=data[i] && data[i]<=max)
        sum += data[i];
```

- Első lépés: két feltételből egyet csinálunk
  - `min<=data[i] && data[i]<=max`

    ↔ `(unsigned)(data[i]-min)<=max-min`
  - Már csak egy feltételünk van:

```
for (int i=0; i<N; i++)
    if ((unsigned)(data[i]-min) <= max-min)
        sum += data[i];
```

- Második lépés: az előbbi trükk

```
for (int i=0; i<N; i++) {
    int t = (max-min-(unsigned)(data[i]-min)) >> 31;
    sum += ~t & data[i];
}
```

ELÁGAZÁSOK SZÁMÁNAK CSÖKKENTÉSE

- 3. példa:

```
for (int i=0; i<N; i++)
   if (!((data[i]>='a' && data[i]<='z') || (data[i]>='A' && data[i]<='Z')))
        data[i] = ' ';
```

- Trükk: segédtömb (**look-up table**, LUT)
  - Minden betűre a cserélendő karakter
- Segédtömb előkészítés + elágazásmentes kód:

```
for (int j=0; j<256; j++)
    if (!((j>='a' && j<='z') || (j>='A' && j<='Z')))
        LUT[j] = ' ';
    else
        LUT[j] = j;
for (int i=0; i<N; i++)
    data[i] = LUT[data[i]];
```

- Az előkészítés ideje fix
  - Ha N nagy, eltörpül

ELÁGAZÁSOK SZÁMÁNAK CSÖKKENTÉSE

- Mérési eredmények:

	i7-2600	Pentium 4	Rasp. Pi	RK3188
1. példa, eredeti	7,583 ms	14,122 ms	59,202 ms	11,296 ms
1. példa, elágazásmentes	1,297 ms	4,251 ms	58,410 ms	8,628 ms
2. példa, eredeti	8,211 ms	19,6 ms	73,267 ms	21,496 ms
2. példa, 1 elágazással	7,942 ms	14,295 ms	61,578 ms	13,347 ms
2. példa, elágazásmentes	1,203 ms	4,252 ms	58,328 ms	8,268 ms
3. példa, eredeti	6,533 ms	10,377 ms	48,532 ms	21,397 ms
3. példa, segédtömbbel	1,151 ms	3,641 ms	37,896 ms	18,240 ms

AZ ELÁGAZÁSOK KISZÁMÍTHATÓBBÁ TÉTELE

- Újra az 1. példa:

```
for (int i=0; i<N; i++)
    if (data[i] > 500)
        sum += data[i];
```

- Elemek rendezetlenek → kiszámíthatatlan kimenetel
- Rendezzük az elemeket!
- Mérések:
  - Rendezetlen eset
  - Rendezett tömb
  - Olyan tömb, amiben minden elemre teljesül
  - Olyan tömb, amiben egyetlen elemre sem teljesül
  - Adott teljesülési minta mellett

AZ ELÁGAZÁSOK KISZÁMÍTHATÓBBÁ TÉTELE

- Mérési eredmények:

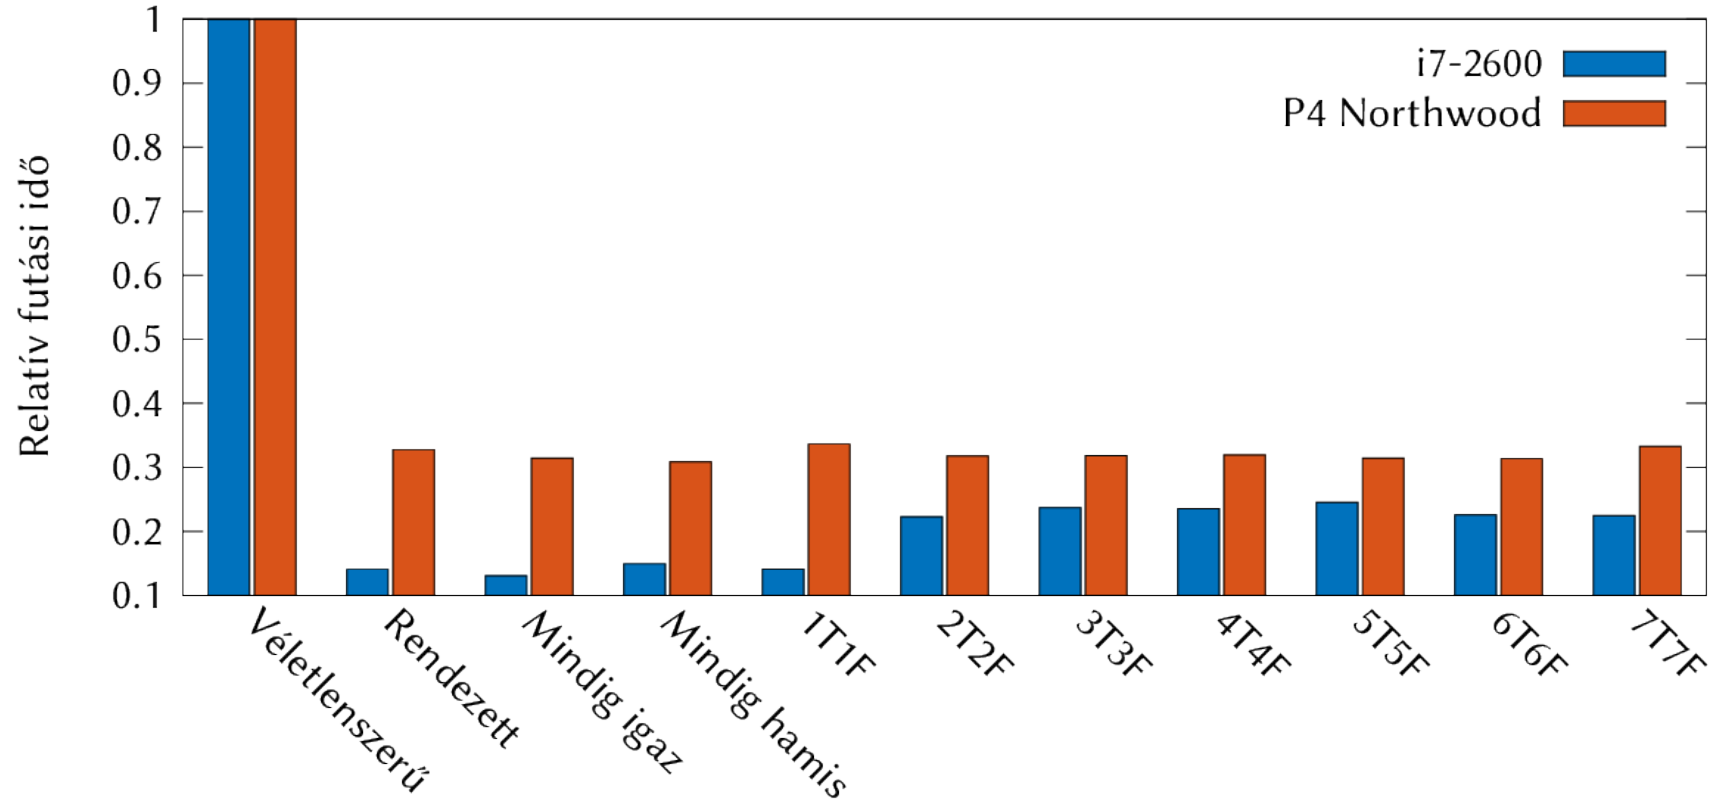

AZ UGRÁSI CÍM BECSÜLHETŐSÉGÉNEK JAVÍTÁSA

- Példa: heterogén kollekció 16 leszármazottal

```
class A {
public:
    virtual int value ()=0;
    virtual int type () const =0;
    virtual ~A() {}
};
```

```
class B1 : public A {
  int v;
public:
  B1 () : v(rand()) {}
  int value () { return ++v; }
  int type () const { return 1; }
  ~B1 () {}
};
```

```
class B16 : public A {
  int v;
public:
  B16 () : v(rand()) {}
  int value () { return ++v; }
  int type () const { return 16; }
  ~B16 () {}
};
```

- Bejárás:

```
sum = 0;
for (i=0; i<siz; i++)
    sum += data[i]->value();
```

- Gond:
  - A virtuális függvényhívás **indirekt** ugrás
  - Az ugrási cím kiszámíthatatlan!
- Megoldás:
  - Rendezzük típus szerint a tömböt!

AZ UGRÁSI CÍM BECSÜLHETŐSÉGÉNEK JAVÍTÁSA

- Mérési eredmények:

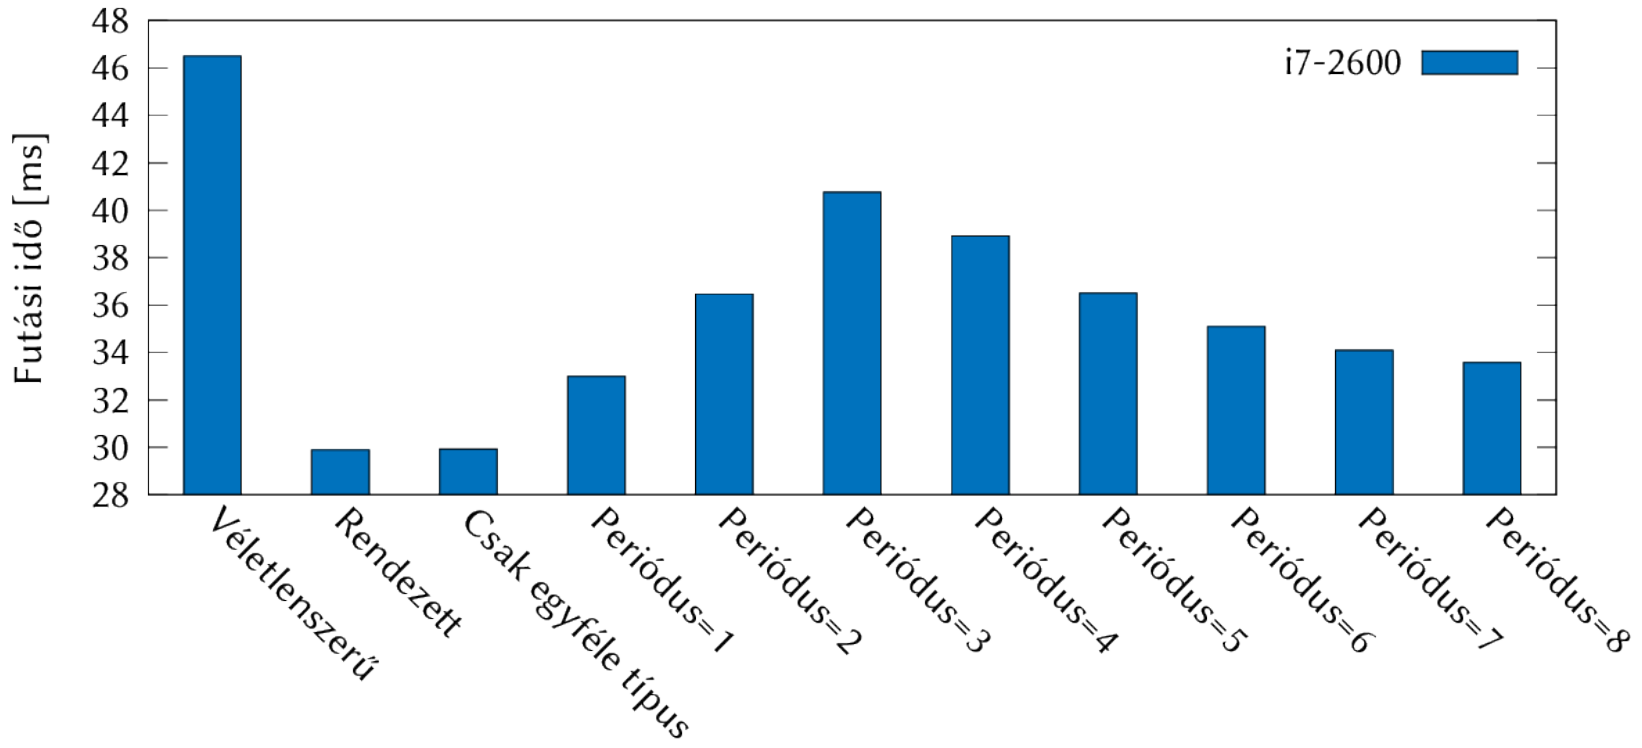

HÁLÓZATI RENDSZEREK
ÉS SZOLGÁLTATÁSOK
TANSZÉK