Az internet ökoszisztémája és evolúciója

Tartalom

- Az IP routerek felépítése
  - routerek általános felépítése, linecard/ backplane/control, a csomagtovábbítás menete, IP router generációk
- FIB keresés
  - a legspecifikusabb prefix keresési feladat
  - hardver és szoftver megvalósítások: a TCAMek, a prefix fa és FIB aggregáció

Az IP routerek felépítése

Routerek: csomagtovábbítás lépései

- **IP csomag ellenőrzése:** formátum, verzió, headerhossz, opciók, fejrész-ellenőrzőösszeg
- **FIB keresés:** a cél IP címéhez tartozó next-hop keresése a FIBben
- A legspecifikusabb bejegyzést keressük!
- **TTL állítása:** ha TTL=0 a csomag eldobása és ICMP üzenet a küldőnek, egyébként
  TTL ← TTL – 1
- **Fejrész-ellenőrzőösszeg újraszámolása**
- Opcionálisan: fragmentáció, source routing, stb.

Nagyteljesítményű routerek

Cisco GSR 12416

Kapacitás: 160 Gb/s
Felvett teljesítmény: 4.2kW

Kapacitás: 80 Gb/s
Felvett teljesítmény: 2.6kW

Juniper M160

Routerek típusai (RFC4098)

- **Edge/border router:** ASek közti forgalom továbbítása más ASek edge routerei felé (iBGP+eBGP+IGP)
- **Core router:** ASen belüli router POPok közti forgalomátvitelre (IGP+iBGP)
- **Access router:** az Internet edge forgalmának koncentrációja a core felé

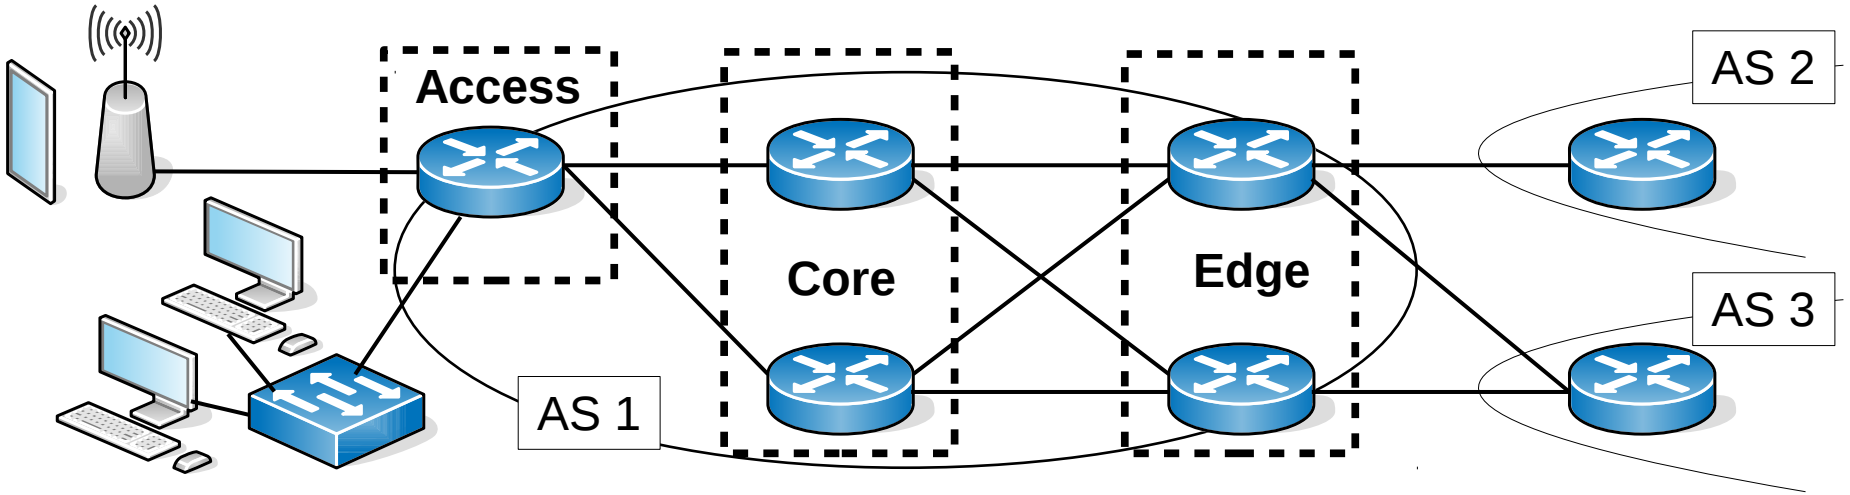

Routerek típusai

- **Soft router:** szoftverben, általános célú CPUn megvalósított router
  - például PC + Linux + Quagga
  - kisebb teljesítmény (Intel DPDK!)
  - főleg kis ISP-k, IXP-k(!), BGP monitorok
- **HW router:** speciális célú HW-t tartalmazó nagy teljesítményű router
  - nagy ISPk core és edge routerei
  - sok előfizetőt kiszolgáló access routerek

Általános felépítés

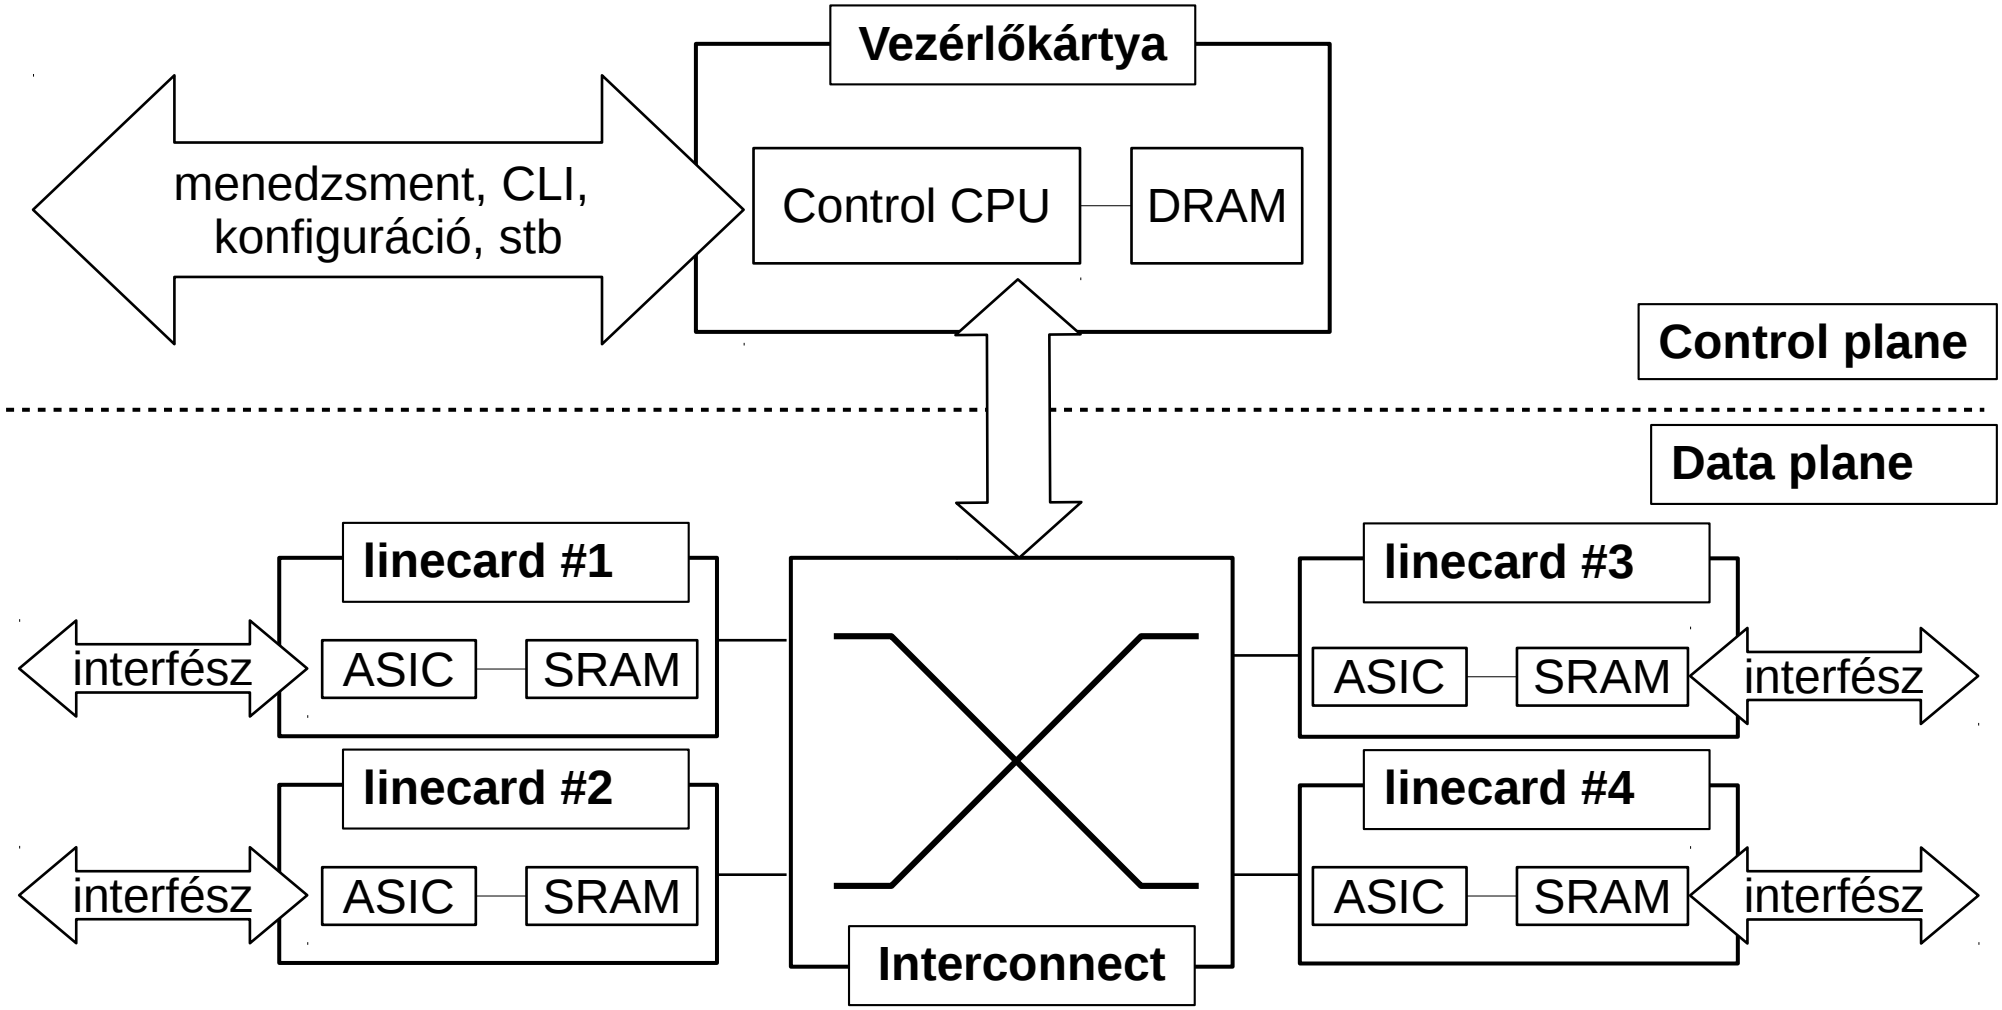

Általános felépítés

- **Vezérlőkártya:** a router logikája
  - routing protokollok futtatása, menedzsment hozzáférés (CLI (Command Line Interface), SNMP, stb.), monitoring, extra szolgáltatások
  - vezérli az interconnect-et, beállítja a FIBet
  - általános célú CPU/DRAM, néha általános célú operációs rendszer (pl. Linux!)

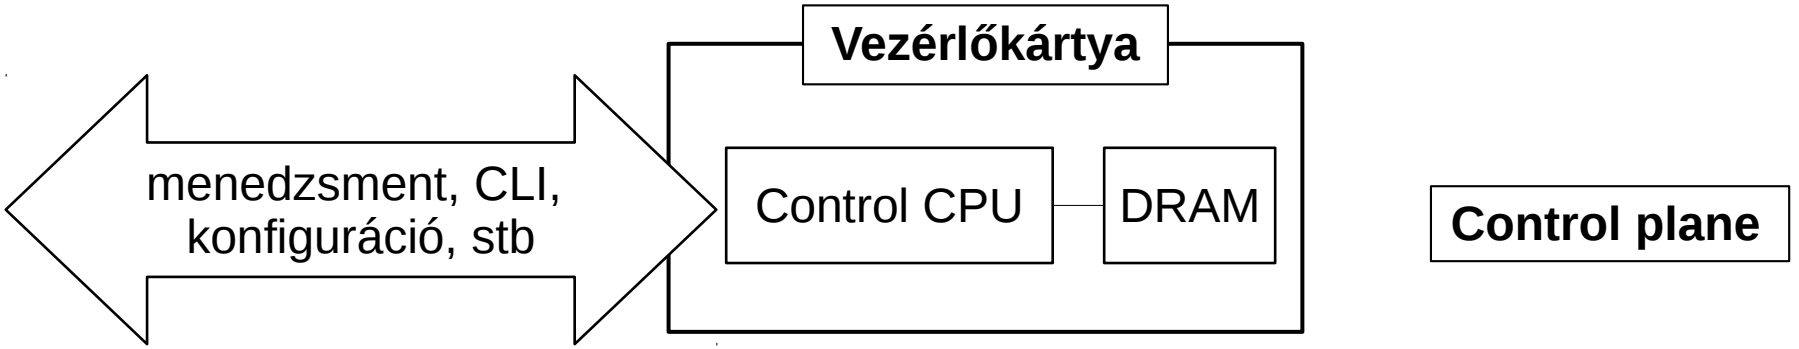

Általános felépítés

- **Interfészkártya (linecard):** csomag adás/vétel
  - egy vagy több fizikai csatoló (interfész) a linkre (Serial/FastEthernet/GigabitEthernet)
  - alapvető csomagtovábbítási funkciók
  - speciális célú HW és gyors statikus memória
  - legtöbb router bővíthető új kártyákkal

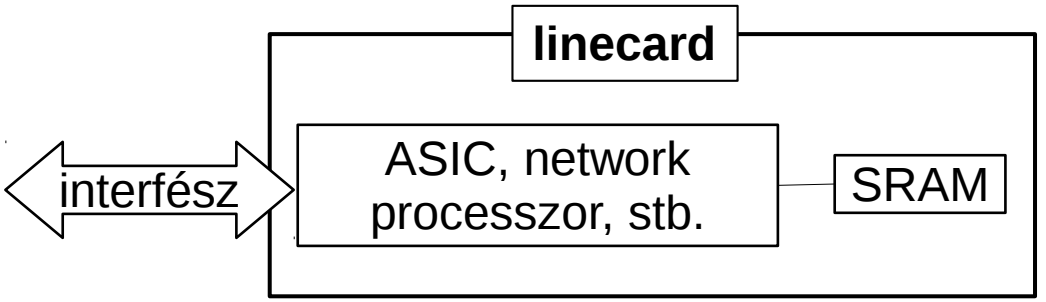

Általános felépítés

- **Interconnect/backplane:** kapcsolólogika
  - interfészkártyák és a control CPU közti kommunikáció + pufferelés
  - osztott busz/belső switch (akár Ethernet)
  - input puffer (head of line blocking!)/output puffer/osztott memória

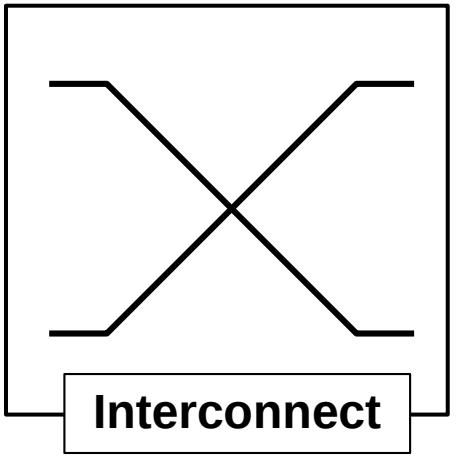

Fast path

- **Fast path:** a csomagtovábbítás **Data plane**-en megvalósított lépései (nagy sebesség!)
  - HWben könnyen megvalósítható műveletek
  - célcím olvasása, ellenőrzőösszeg számítása
  - sokszor a FIB keresés is (de ehhez le kell tölteni a FIBeket az interfészkártyákra!)

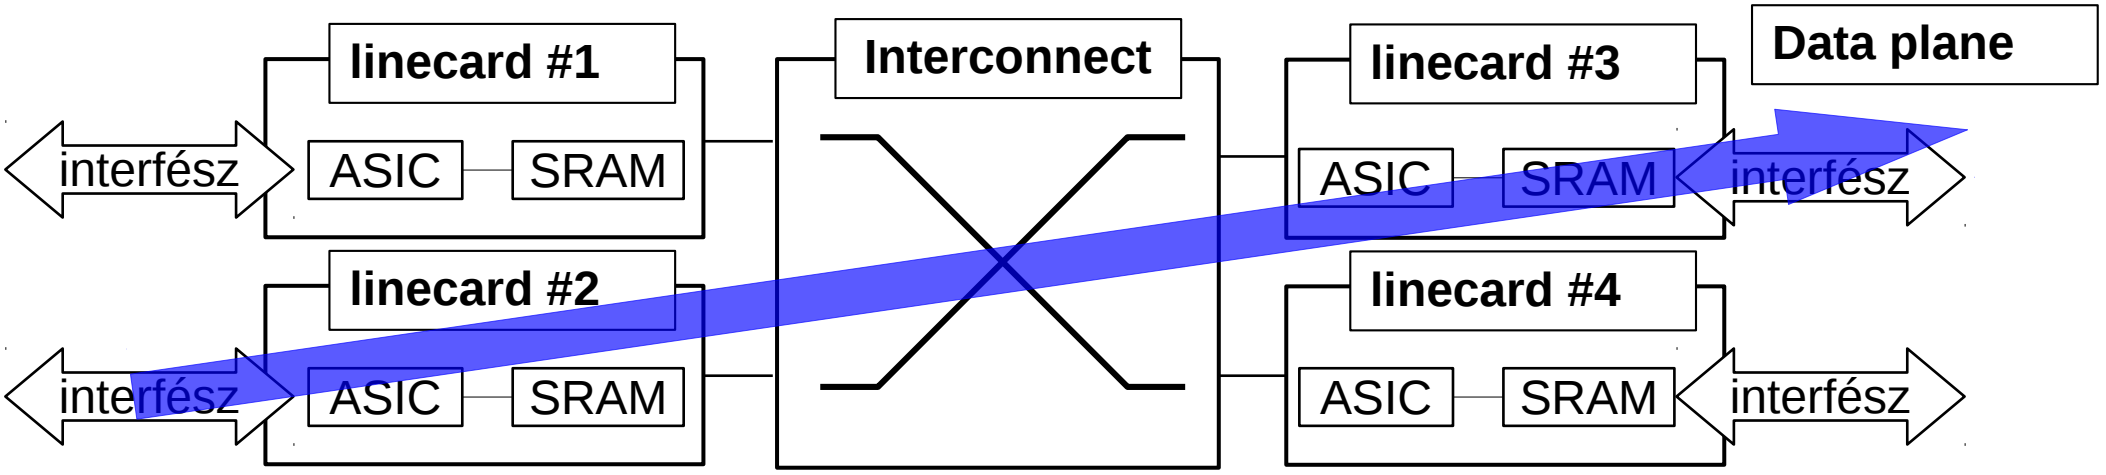

Slow path

- **Slow path:** a vezérlősík beavatkozását igénylő „bonyolultabb” funkciók (csökkent sebesség!)
  - IP opciók, fragmentáció, protokollüzenetek kezelése, ARP, ICMP generálás, stb.

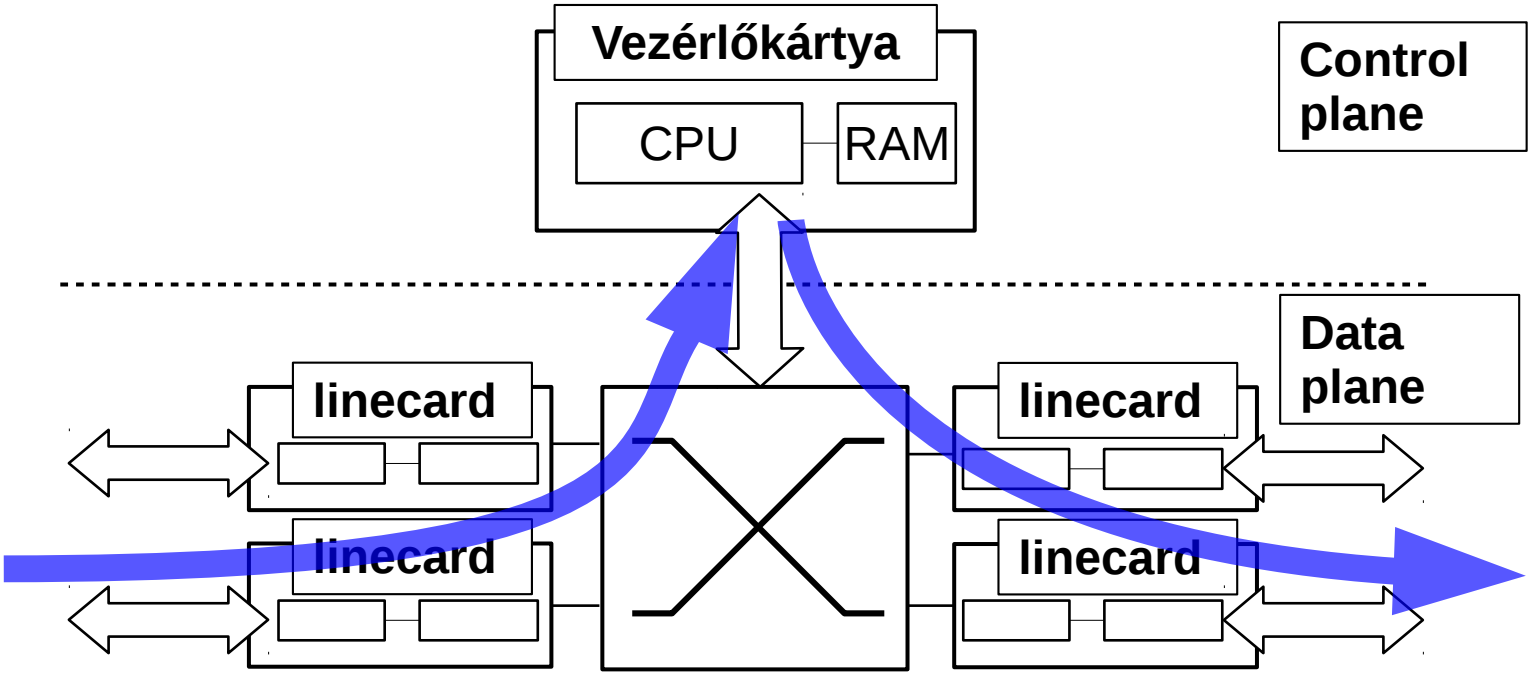

Routerek fejlődése: 1. generáció

- A hálózati csatoló kivételével minden a slow path-en, minden csomag igényli a vezérlősík beavatkozását

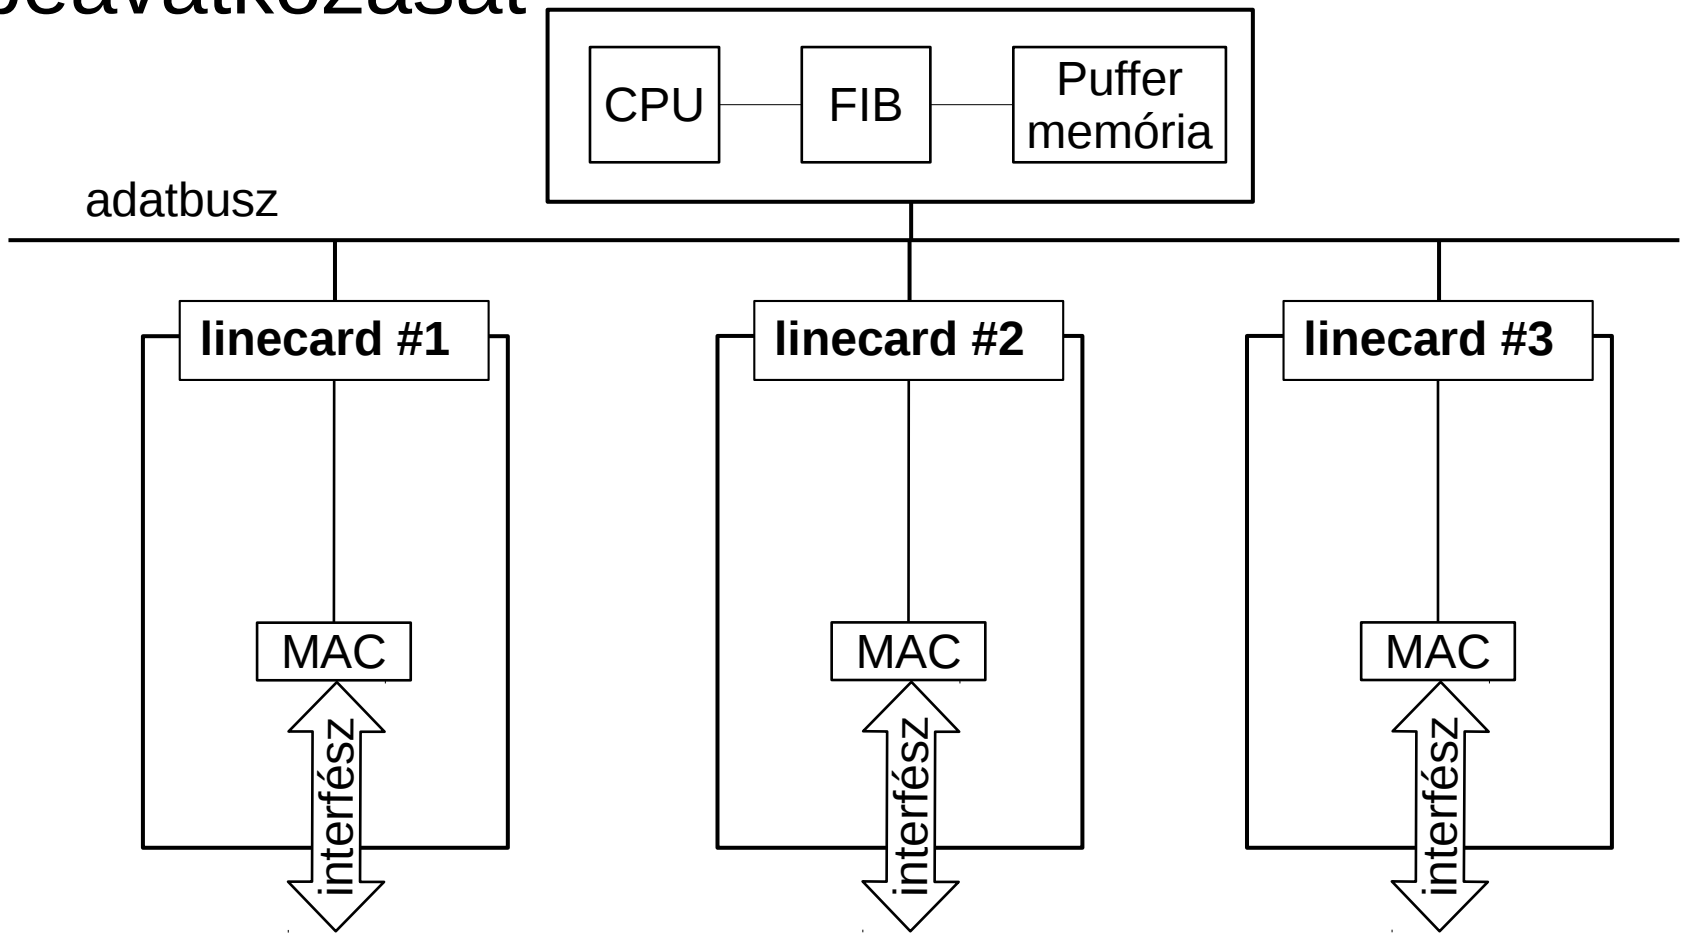

Routerek fejlődése: 2. generáció

- Az interfészkártyán: input puffer + FIB cache
- Fast path továbbítás, ha a célcím a cache-ben

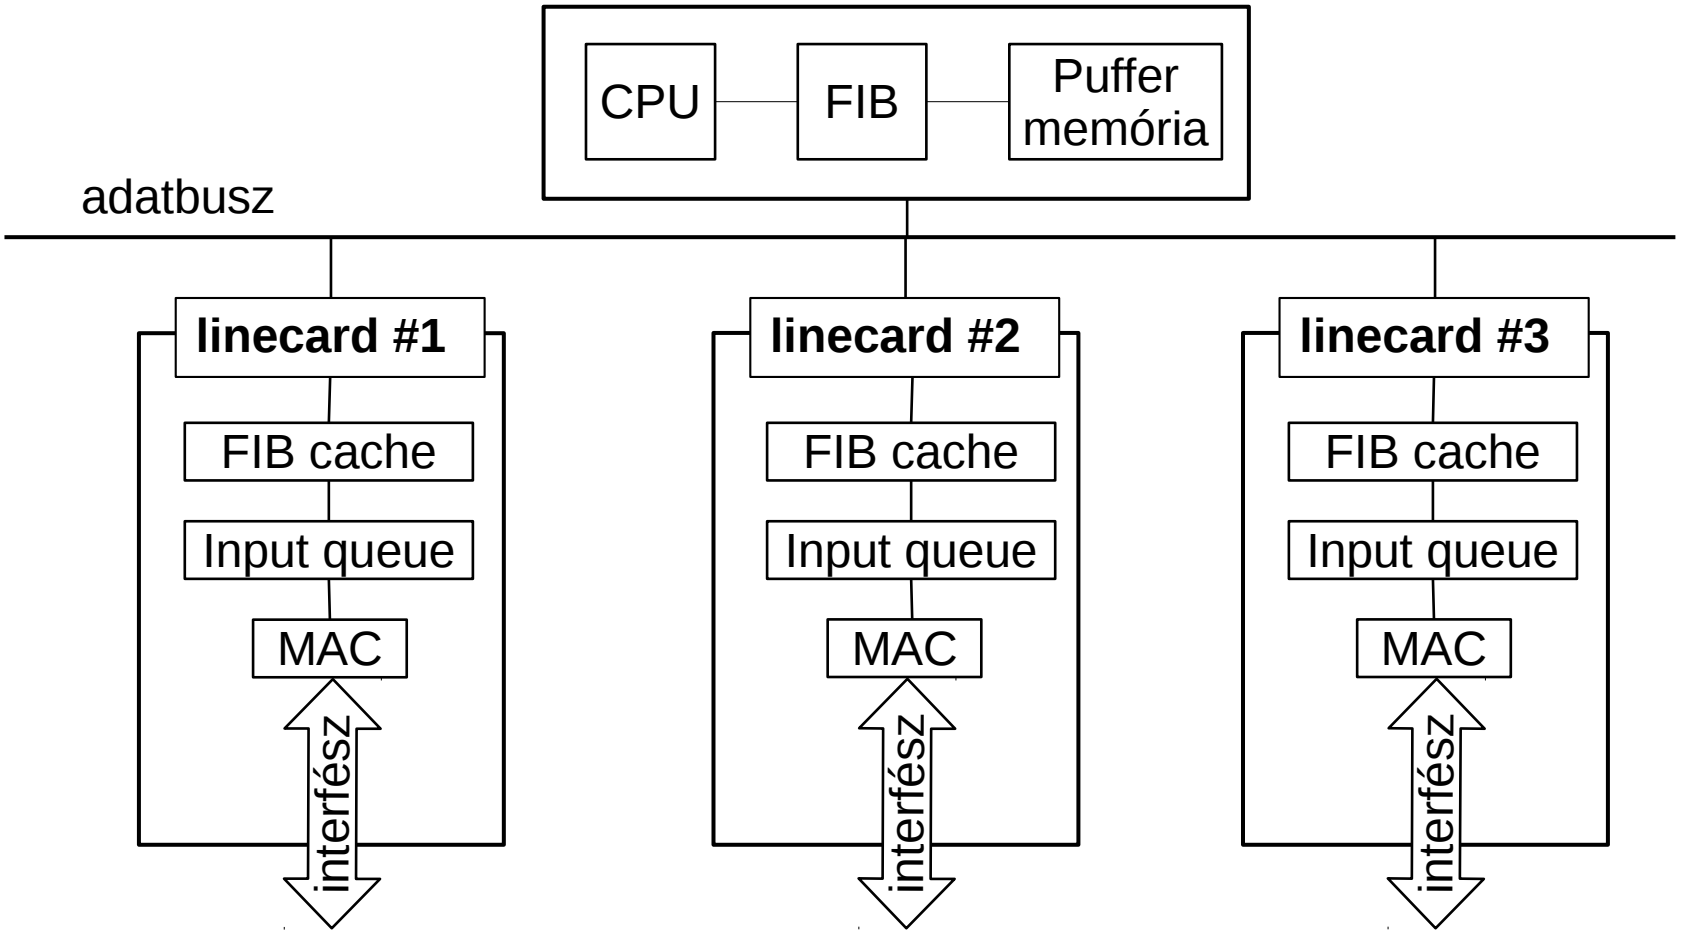

Routerek fejlődése: 3. generáció

- Az interfészkártyán a teljes FIB, szinte minden csomag marad a fast path-en
- A CPU csak egy másik kártya a chassis-ben

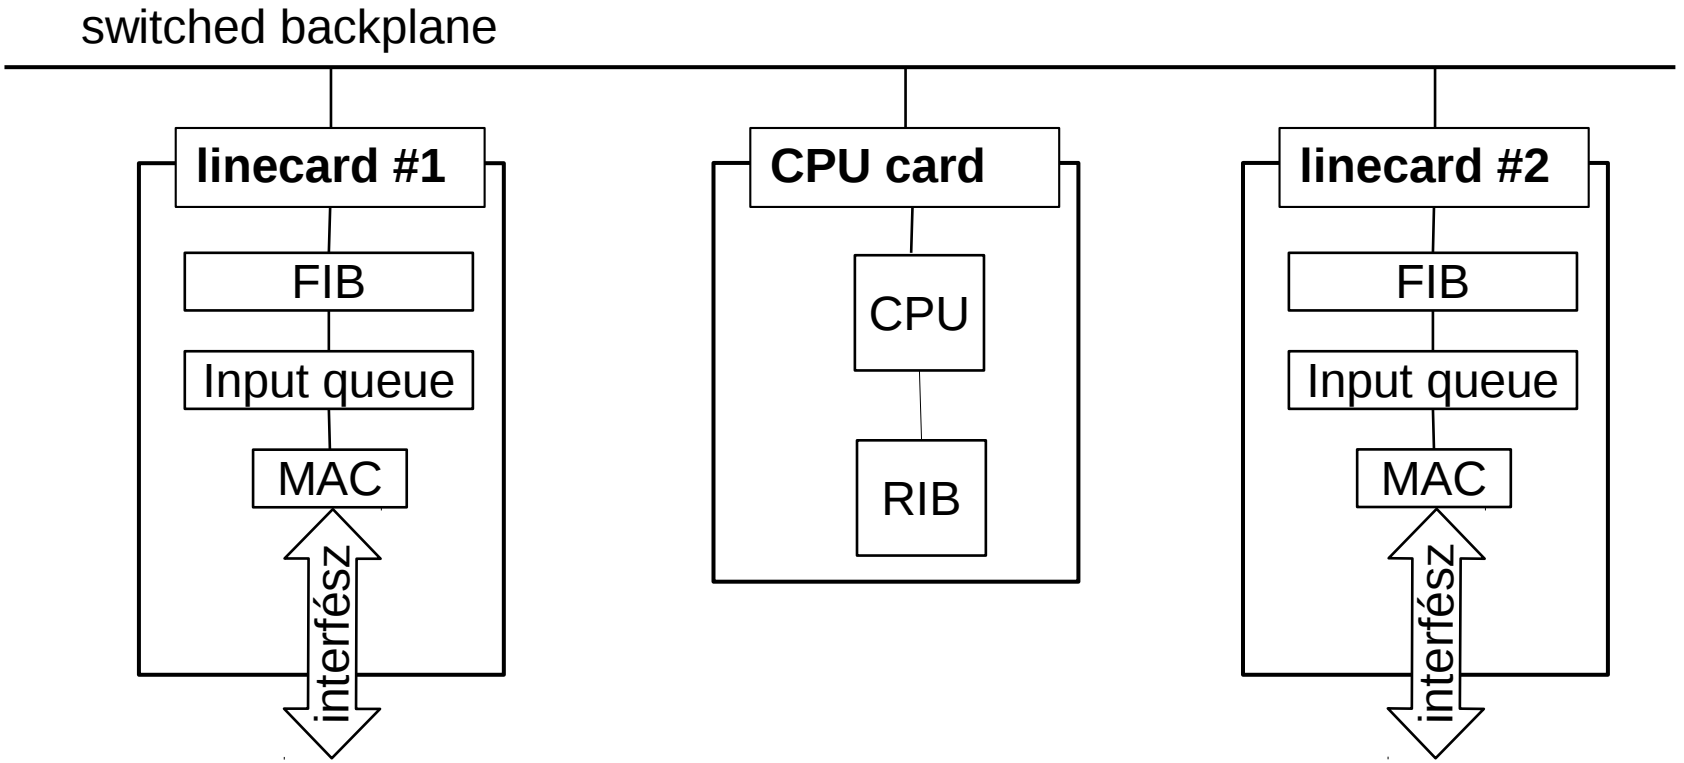

Routerek fejlődése: a jövő?

- A mai általános célú CPUk gyakran vannak olyan gyorsak, mint egy ASIC
  - ráadásul sokkal olcsóbbak is
  - Moore-törvénye miatt gyorsan fejlődnek
  - a csomagtovábbítás masszívan párhuzamos feladat: csomagonként akár külön CPU végzi
- A fejlődés az olcsó, masszívan parallel, virtualizált szoftver-routerek felé mutat
- Akár nem is különálló doboz, hanem a cloud-ban fut (Intel DPDK)!

FIB keresés

FIB keresés

- Az IP csomagtovábbítás legidőigényesebb feladata: a csomagban található célcím alapján meg kell találni a megfelelő next-hopot
  - a legspeficikusabb bejegyzés kell (LPM)
- **FIB (Forwarding Information Base):** a csomagtovábbítási szabályok összessége
- Az útvonalválasztó protokollok adatai alapján a control CPU tölti le az interfészkártyákra
- Így azok a control CPU igénybevétele nélkül, fast path-en továbbítják a csomagokat

FIB keresés: LPM

- A LPM megvalósítása nem triviális
- Egy naiv megközelítés végigkeresné az összes bejegyzést a FIBben és megjegyezné a legtöbb biten illeszkedőt
- *O(N)* komplexitás, ha a bejegyzések száma *N*
- A gyakorlatban $N \approx 10^6$, a rendelkezésre álló időkeret pedig 500 byte-os csomagokkal számolva 10Gbit/s sebességen 1GHz-es órajelen alig 400 órajel
- A naiv módszer használhatatlan

Tartalomcímezhető memóriák

- **Content Addressable Memory (CAM)**
- Pontosan a klasszikus memóriák ellentéte:
  - RAM: cím alapján megadja a tárolt adatot
  - CAM: az adathoz megkeresi annak címét
  - ha több adat stimmel, az első címét adja meg

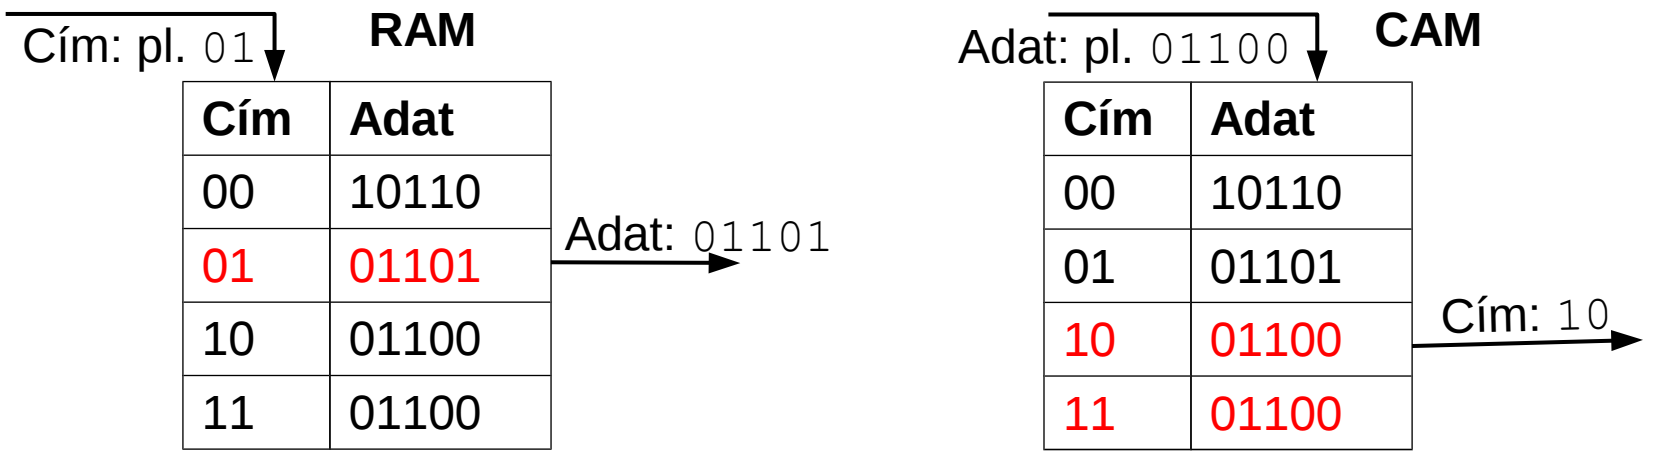

Háromállapotú CAM: TCAM

- **Ternary Content Addressable Memory:** a CAM csak `0` és `1` értékű biteket ismer, a TCAM mintákban beállítható "Don't care" bit is (`*`)
- Például az `101**` TCAM minta illeszkedik `10100`, `10101`, `10110` és `10111` lekérdezésekre
- `*` bárhol szerepelhet, nemcsak a minta végén!
- Alacsonyabb címen levő minták előbb illesztve
- Illeszkedő minta esetén kiszállás a címmel
- Az alacsonyabb címen levő minták felülbírálják a magasabb címen levő mintákat: **prioritás**

Háromállapotú CAM: TCAM

- A `00110` keresésre a `00` és az `11` címen levő minta is illeszkedik, az első preferált, output: `00`
- Az `11111` keresésre az eredmény: `10`
- `01110` keresésre a `10` és az `11` címen levő minta is illeszkedik, output: `10`

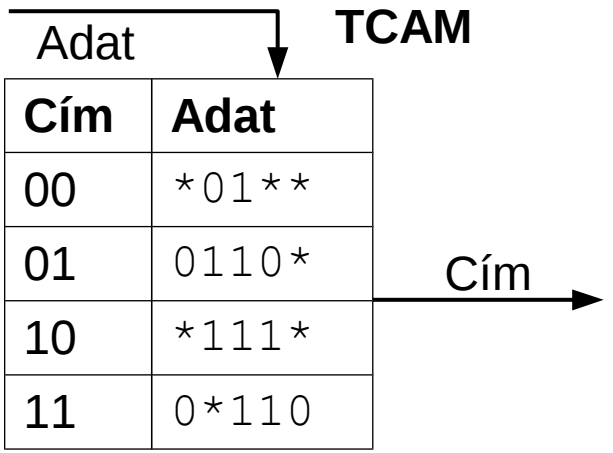

TCAM: megvalósítása

- *(Mintaszám * bitszélesség)* számú cella, mindegyikben `0/1/*` tárolva és egy komparátor
- A cellák egyszerre végzik az összehasonlítást
- Kimeneti logika választja ki a legkisebb címet

TCAM

Adat: `01101`

Cím	Adat
00	`101**`
01	`0110*`
10	`011**`
11	`10011`

Cím: `01`

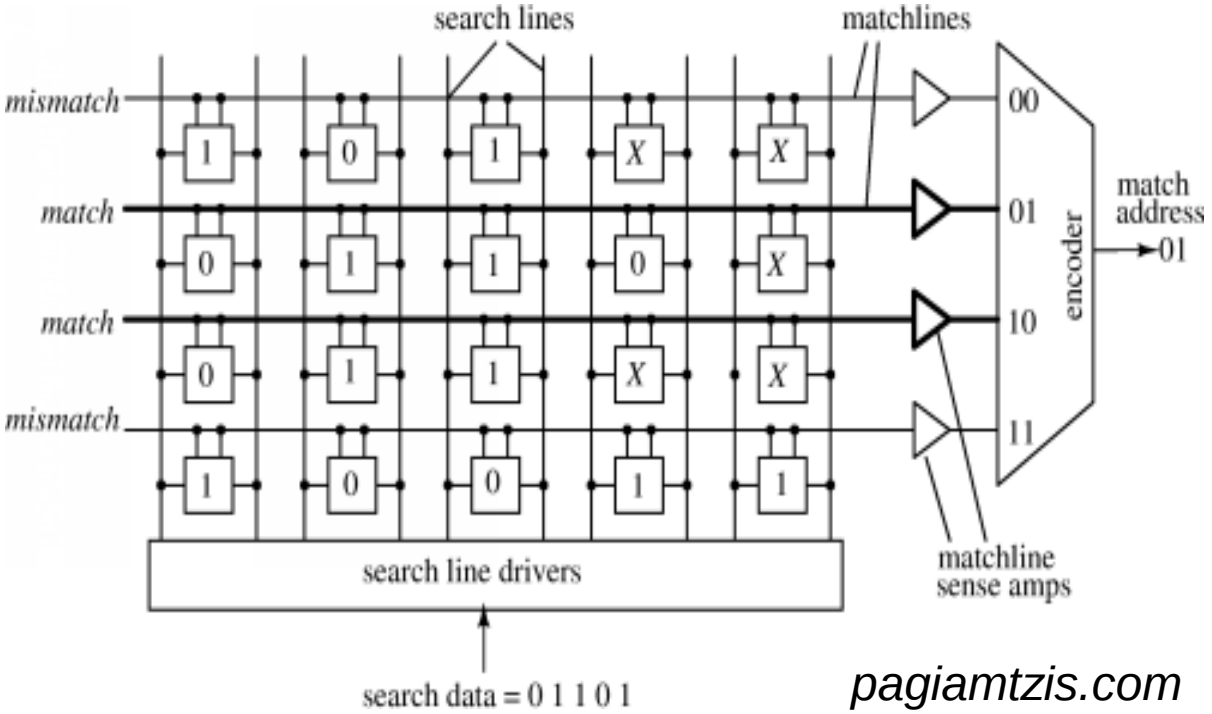

pagiamtzis.com

TCAM: a LPM megvalósítása

- Tekintsük az alábbi FIBet

IP prefix	Bináris prefix	Next-hop
`160.0.0.0/3`	`101`	`10.0.0.1`
`96.0.0.0/4`	`0110`	`10.0.0.2`
`96.0.0.0/3`	`011`	`10.0.0.3`
`184.0.0.0/5`	`10111`	`10.0.0.2`

- Minden csomaghoz a cél IP címére a legtöbb biten illeszkedő FIB-bejegyzést keressük
- A `96.128.59.12` IP címre a 2. és 3. bejegyzés is illeszkedik, de a 2. több biten, így az preferált
- LPM eredménye: a 2. bejegyzés-beli next-hop

TCAM: a LPM megvalósítása

- Használjunk az LPM megvalósítására TCAMet
- Az alhálózati prefix bitjeit pontosan megadjuk
- Ezeket a biteket a TCAM pontosan illeszti
- A hoszt-azonosítót * bitekkel helyettesítjük
- Hisz ezen bitek nem számítanak az LPM-ben
- Így csak az utolsó pozíciókban állhat *

Cím	IP prefix	Illesztendő TCAM minta	Next-hop
00	160.0.0.0/3	101***** ******** ******** ********	10.0.0.1
01	96.0.0.0/4	0110**** ******** ******** ********	10.0.0.2
10	96.0.0.0/3	011***** ******** ******** ********	10.0.0.3
11	184.0.0.0/5	10111*** ******** ******** ********	10.0.0.2

TCAM: a LPM megvalósítása

- **Probléma:** ha ebben a sorrendben írjuk a TCAMbe a mintákat, egy kevésbé specifikus prefix felülírhatja a specifikusabbat (pl. a `184.1.1.1` címre az 1. minta lenne a kimenet, de a 4. a jó LPM találat, hiszen hosszabb)
- **Megoldás:** rendezzük át a bejegyzéseket a prefix-hossz szerinti csökkenő sorrendbe
  - a legspecifikusabb bejegyzésekhez tartozó minták (vagyis a leghosszabb prefixek) kerülnek alacsony címekre = magas prioritás
  - kevésbé specifikus prefixek: magasabb cím

TCAM: a LPM megvalósítása

- A FIB bejegyzések szabadon átrendezhetők
- Hiszen pontos prioritást ad a prefix-hossz
- A prefix-hossz szerinti csökkenő sorrendbe rendezés után kapott táblázat

Cím	IP prefix	Illesztendő TCAM minta	Next-hop
00	184.0.0.0/5	10111*** ******** ******** ********	10.0.0.2
01	96.0.0.0/4	0110**** ******** ******** ********	10.0.0.2
10	96.0.0.0/3	011***** ******** ******** ********	10.0.0.3
11	160.0.0.0/3	101***** ******** ******** ********	10.0.0.1

- A pirossal jelzett oszlopok TCAMbe írhatók
- A maradék oszlopokat RAMban tároljuk

TCAM: a LPM megvalósítása

- **HW FIB:** TCAM és RAM összekapcsolása
- A TCAMből kiolvasott címmel címezzük a RAMot, amelyből kiolvassuk a next-hop címét
- Elég 5 bit széles TCAM (max. prefix-hossz)

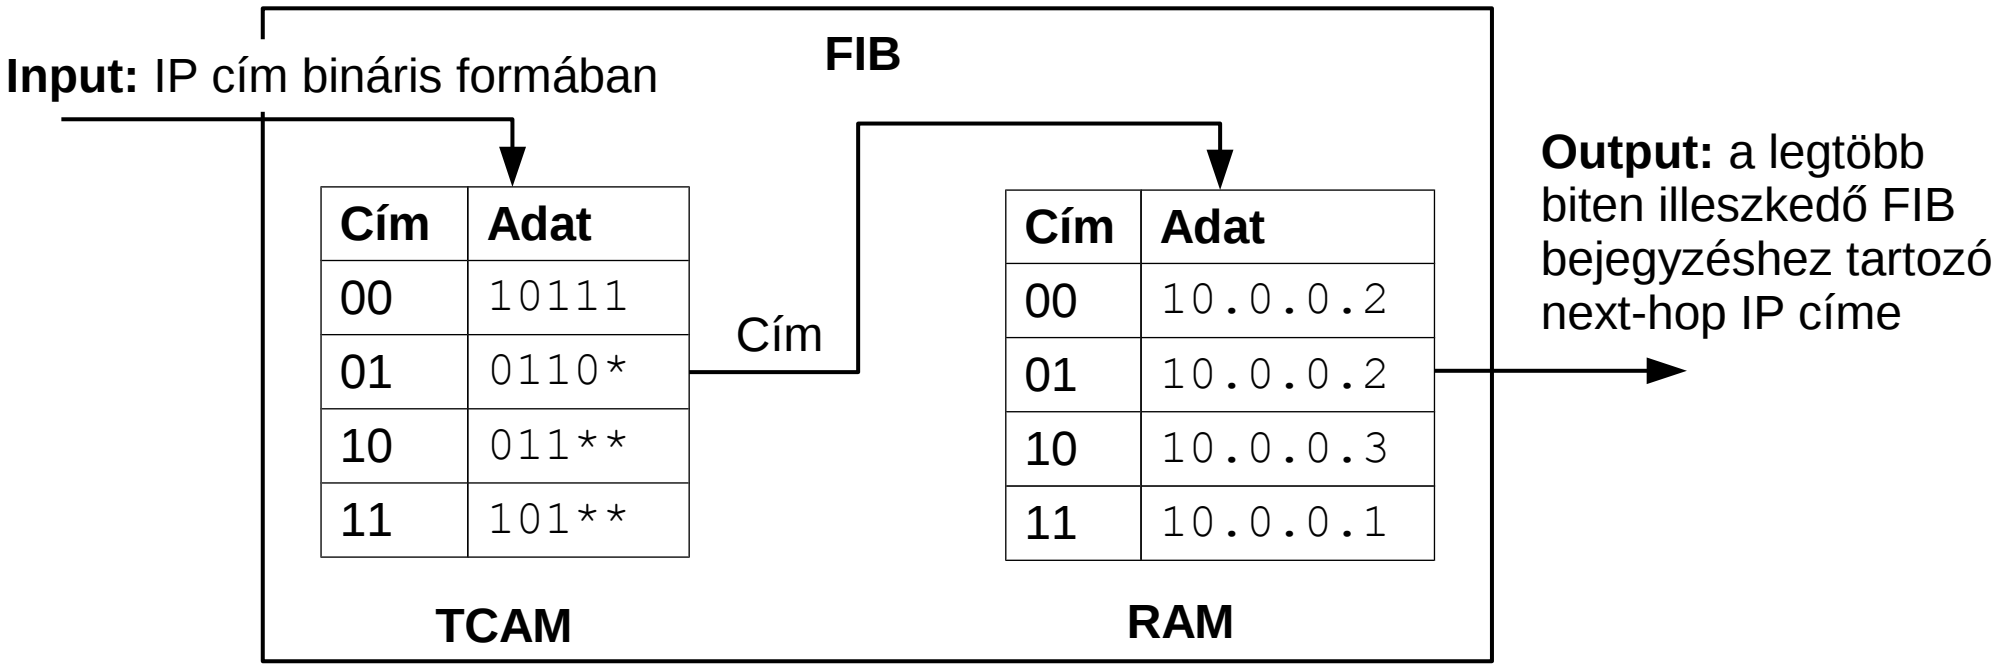

TCAM: a LPM megvalósítása

- A `184.1.1.1=10111...` IP címre a TCAM a `00` címet adja
- A RAMból a `00` címen kiolvassuk a next-hopot

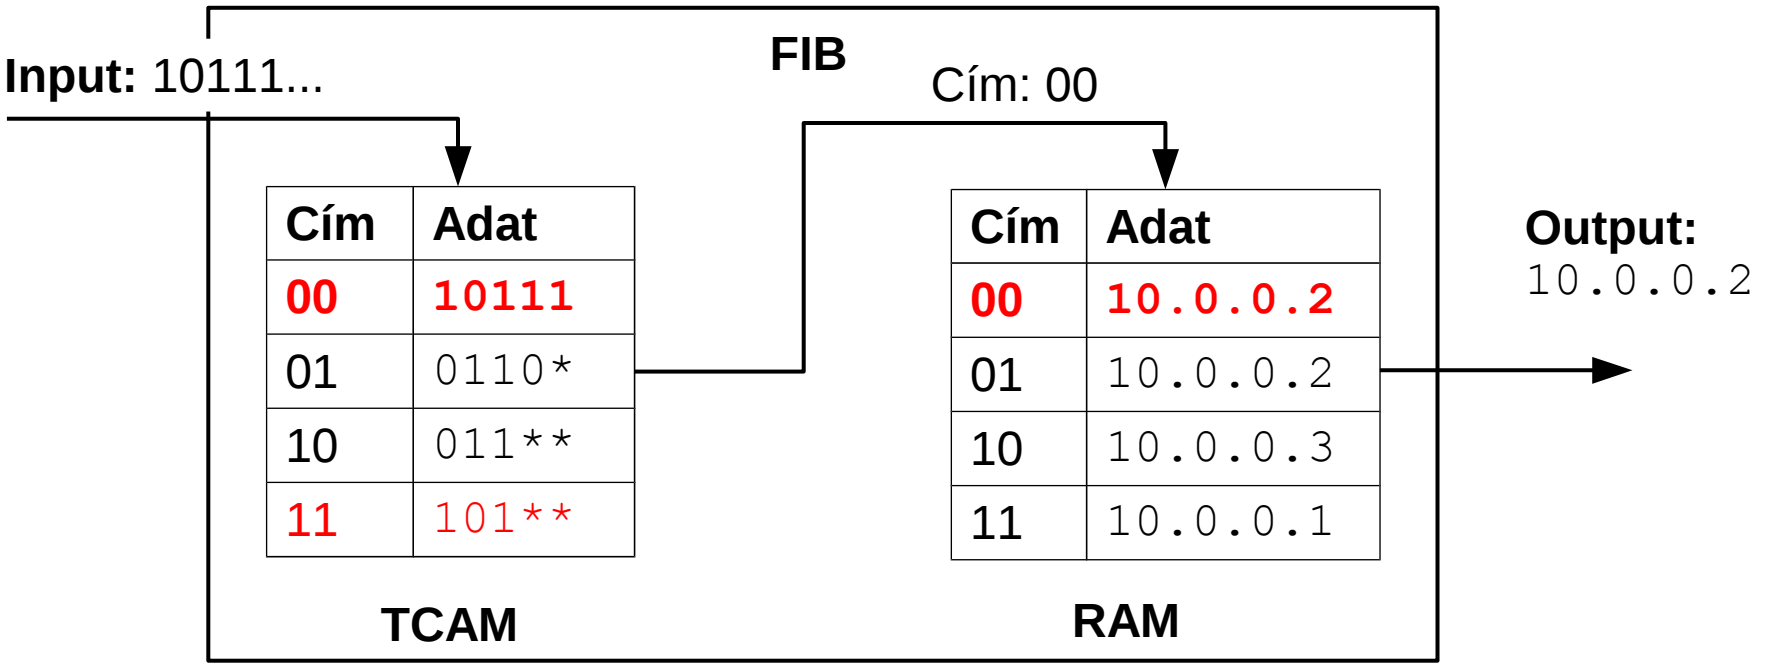

TCAM: a LPM megvalósítása

- A `97.12.124.45=01100...` IP címre a 2. és a 3. TCAM bejegyzés is illeszkedik
- A TCAM a `01` címet adja, a next-hop: `10.0.0.2`

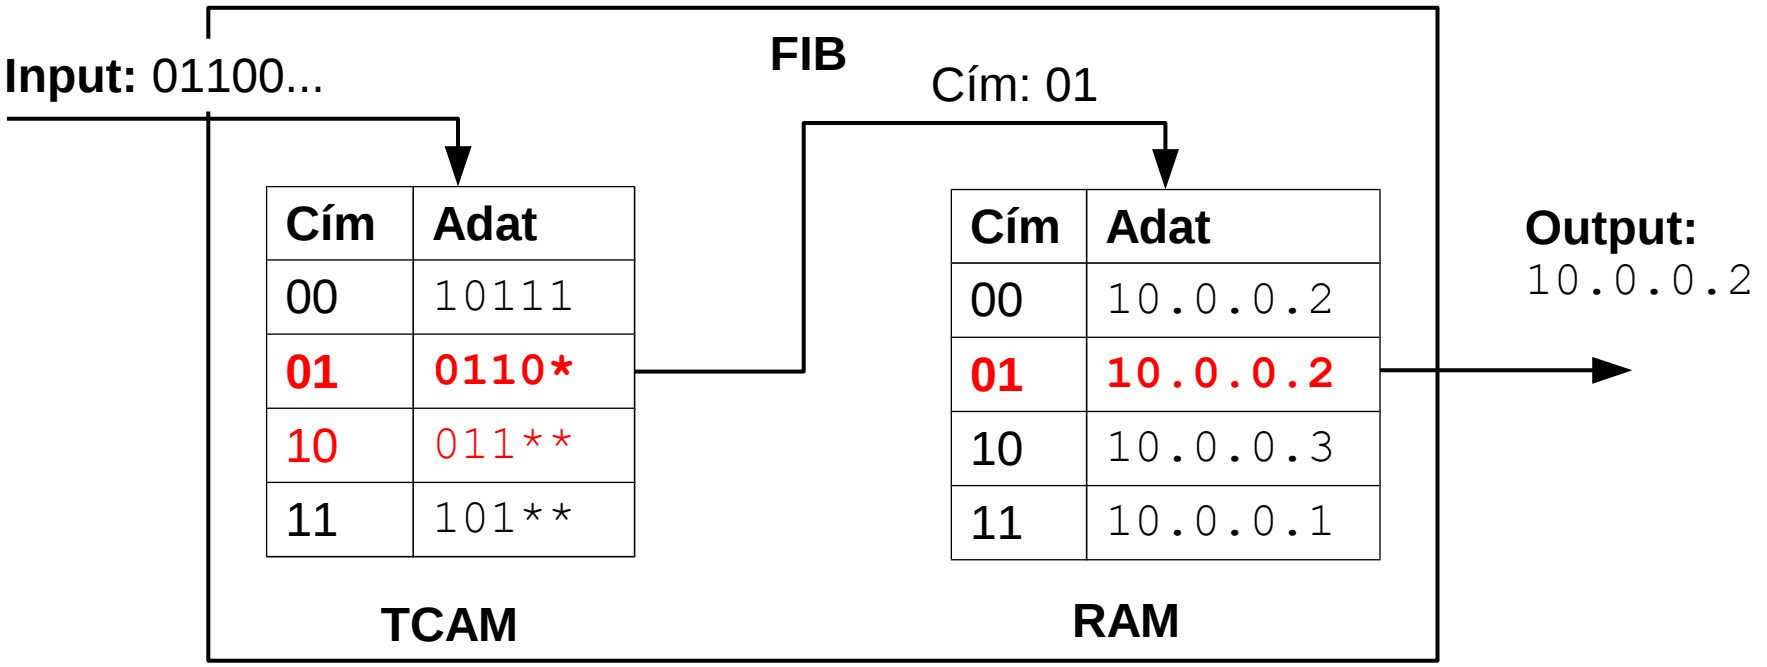

TCAM: a LPM megvalósítása

- A routerekben alkalmazott HW ASICek a TCAMet és a RAMot is tartalmazzák (egyben)
- Pár órajel alatt kész az LPM keresés: nagyon gyors fast-path IP csomagtovábbítás
- Elterjedt egyéb feladatokra is: Ethernet MAC learning tábla, firewall szabályok kódolása, stb.
- De a TCAM bonyolult: 16 tranzisztor/cella (SRAM: 6, DRAM: 2 tranzisztor/cella): drága!
- Magas a fogyasztása (9MB TCAM csip, 100 MHz órajel, 10–15W disszipáció): melegszik!

A LPM megvalósítása SWben

- Nem minden felhasználásra célszerű a TCAM
  - soft routerek, egyszerű access routerek (pl. SOHO router), virtualizált routerek (cloud)
- Hasznos lenne egy olyan FIB adatstruktúra, amely gyors keresést tesz lehetővé általános célú CPUn implementálva
- Egy általános CPUn a legköltségesebb művelet a memóriahozzáférés
- **Cél:** a LPM megvalósításához szükséges RAM olvasások számának minimalizálása

A (bináris) prefix fa

- LPM keresésre optimalizált adatstruktúra
- A **prefix fa** a következő műveleteket támogatja:
  - **keresés:** adott mintára legtöbb biten illeszkedő prefix megtalálása és a hozzá tárolt címke kiolvasása
  - **beszúrás:** (prefix → címke) páros beillesztése
  - **törlés:** prefix és hozzá tartozó címke törlése
  - **módosítás:** prefix címkéjének módosítása

A prefix fa

- Tekintsük a korábbi FIBet és bontsuk két részre
- A next-hopokat azonosítsuk **egyedi címkékkel** és tároljuk külön egy **next-hop index** táblában

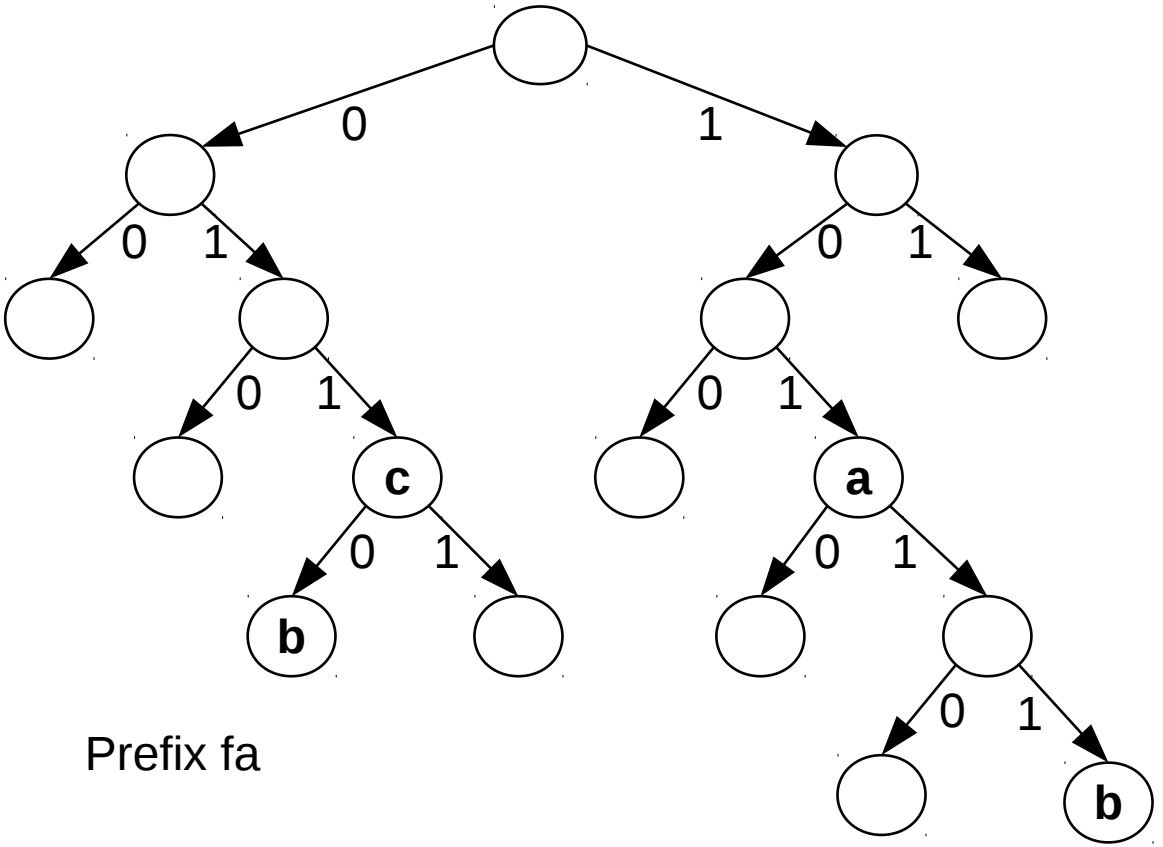

Prefix fa

FIB

IP prefix	Prefix	Címke
160.0.0.0/3	101	a
96.0.0.0/4	0110	b
96.0.0.0/3	011	c
184.0.0.0/5	10111	b

Next-hop index

Címke	Next-hop
a	10.0.0.1
b	10.0.0.2
c	10.0.0.3

A prefix fa

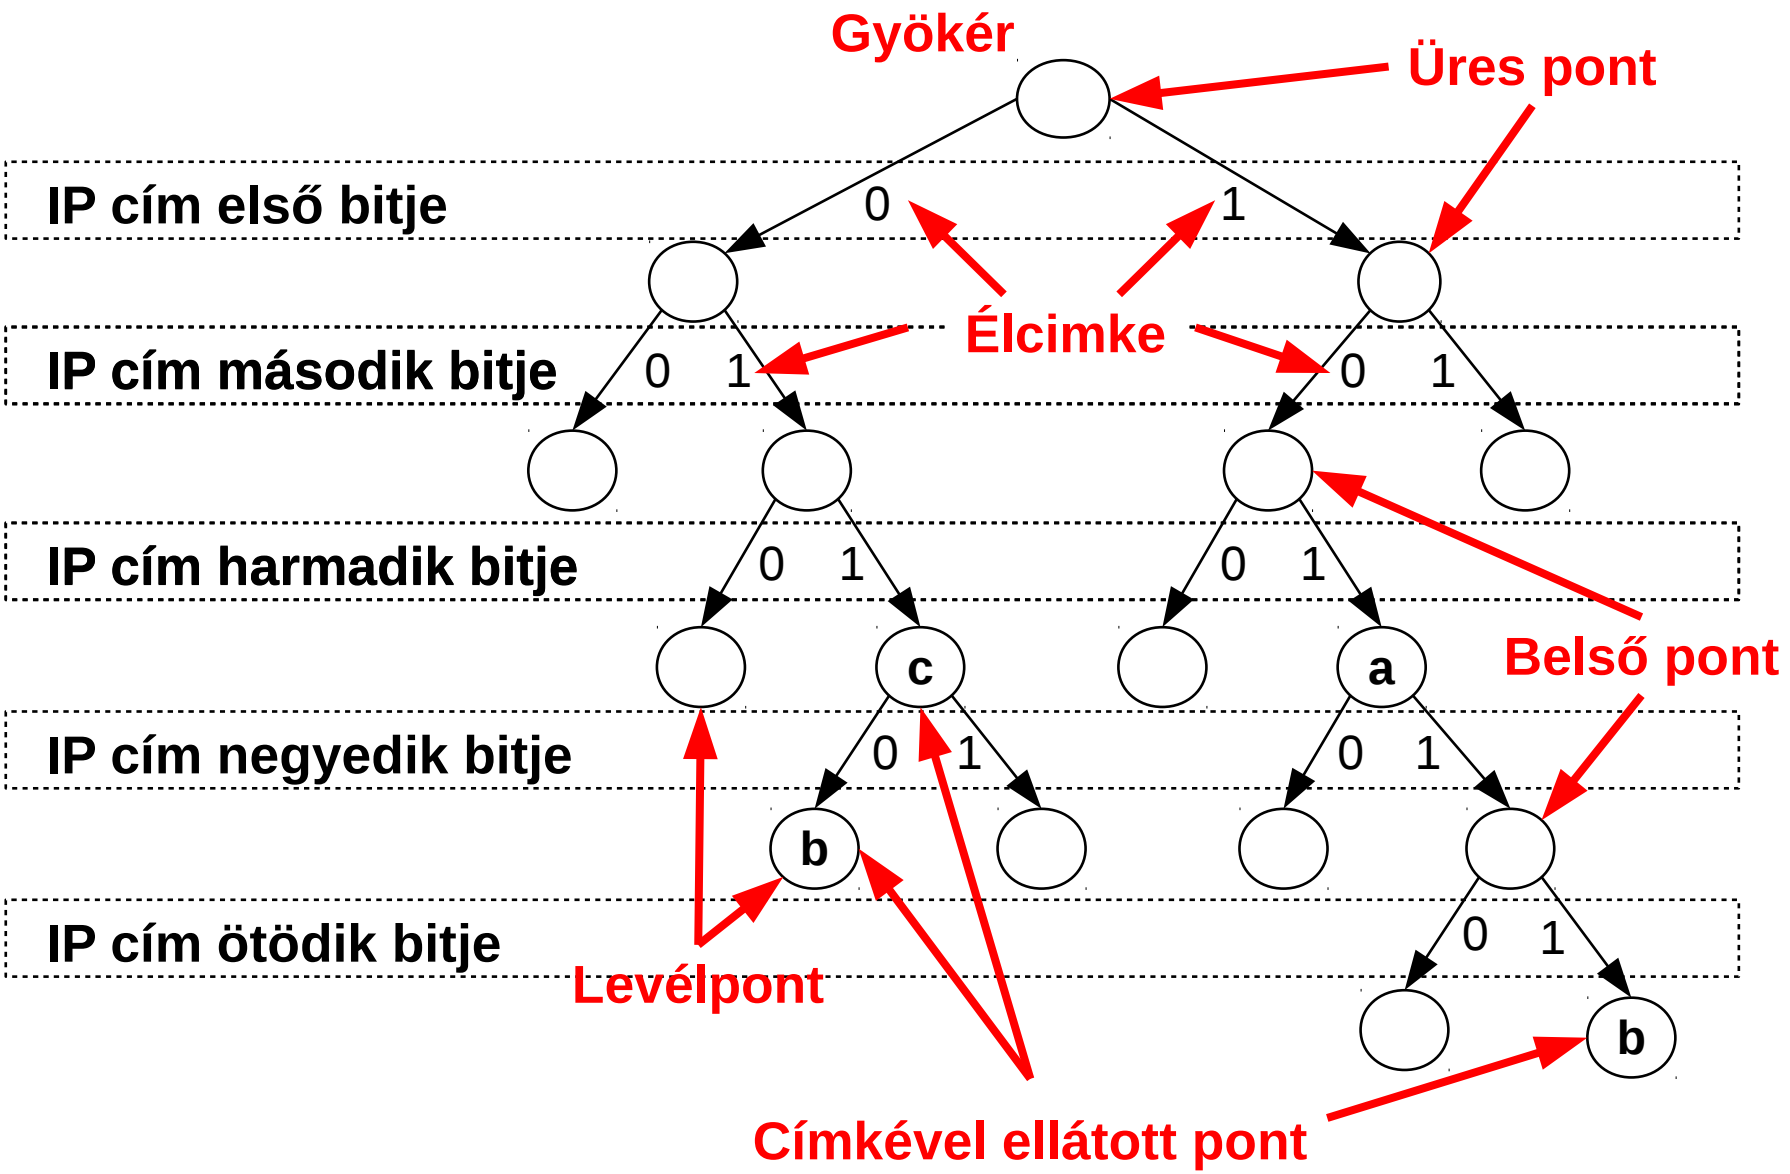
Gyökér
Üres pont
IP cím első bitje
0
1
Élcimke
IP cím második bitje
0
1
0
1
IP cím harmadik bitje
0
1
0
1
c
a
Belső pont
IP cím negyedik bitje
0
1
0
1
b
IP cím ötödik bitje
0
1
b
Levélpont
Címkével ellátott pont

A prefix fa

- **Prefix=pontba vezető út élcímkéinek sorozata**
- A fában a prefixeknek megfelelő pontokat a prefixhez tartozó next-hop címkével jelöljük

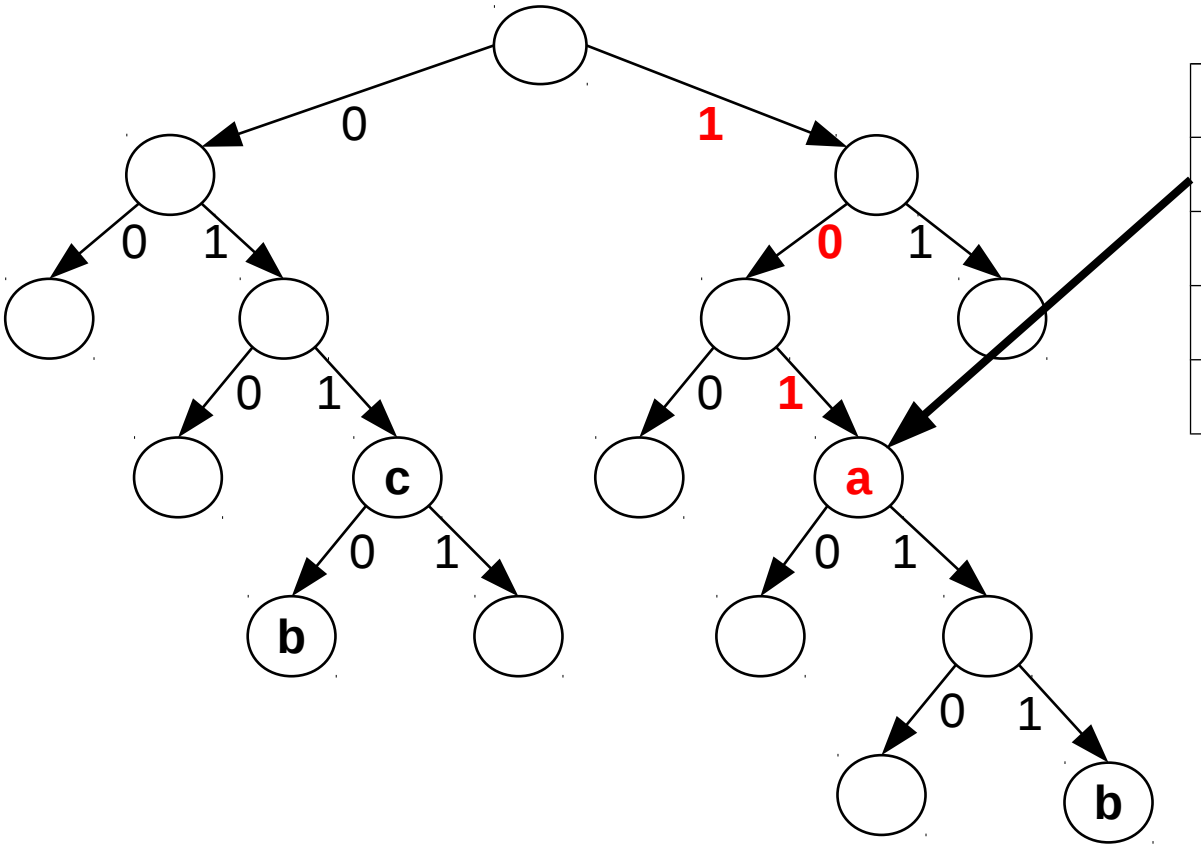

FIB

IP prefix	Prefix	Címke
160.0.0.0/3	**101**	**a**
96.0.0.0/4	0110	b
96.0.0.0/3	011	c
184.0.0.0/5	10111	b

Next-hop index

Címke	Next-hop
a	10.0.0.1
b	10.0.0.2
c	10.0.0.3

A prefix fa

- **Prefix=pontba vezető út élcímkéinek sorozata**
- A fában a prefixeknek megfelelő pontokat a prefixhez tartozó next-hop címkével jelöljük

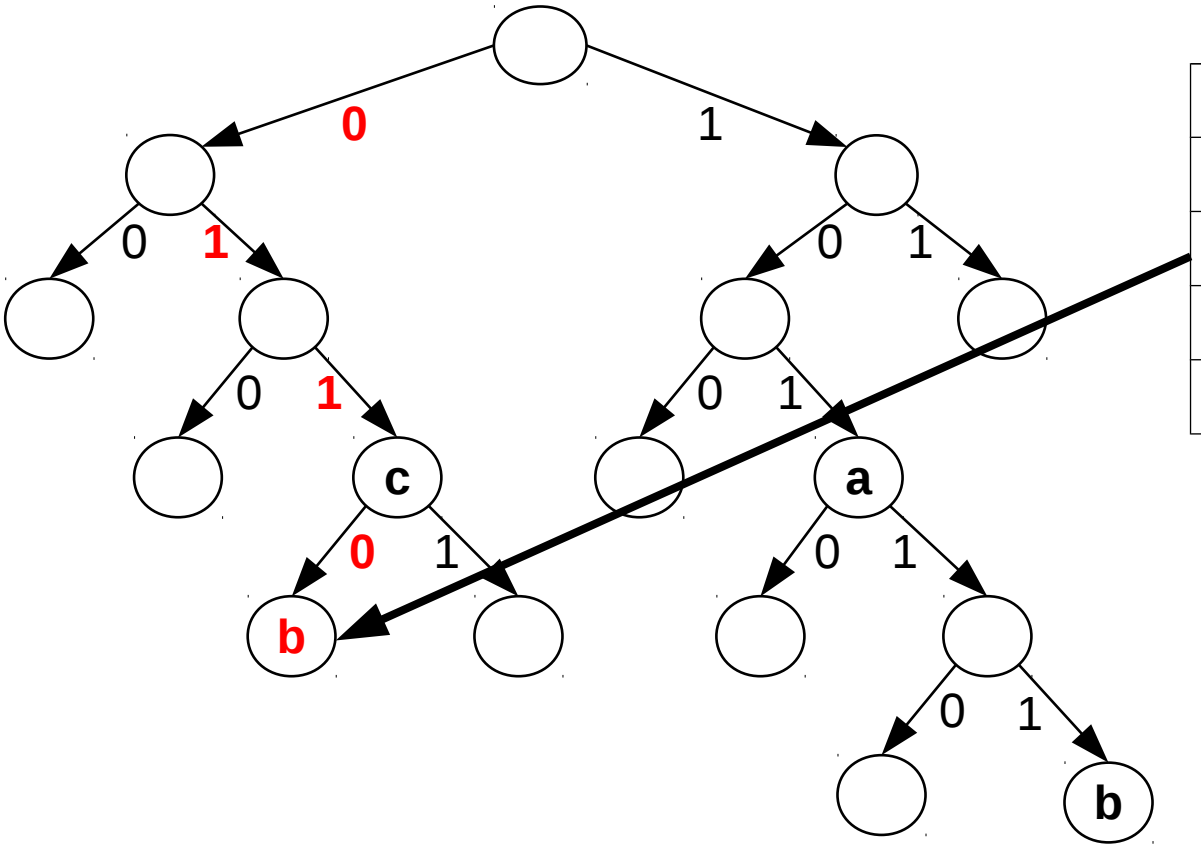

FIB

IP prefix	Prefix	Címke
160.0.0.0/3	101	a
96.0.0.0/4	**0110**	**b**
96.0.0.0/3	011	c
184.0.0.0/5	10111	b

Next-hop index

Címke	Next-hop
a	10.0.0.1
b	10.0.0.2
c	10.0.0.3

A prefix fa

- **Prefix=pontba vezető út élcímkéinek sorozata**
- A fában a prefixeknek megfelelő pontokat a prefixhez tartozó next-hop címkével jelöljük

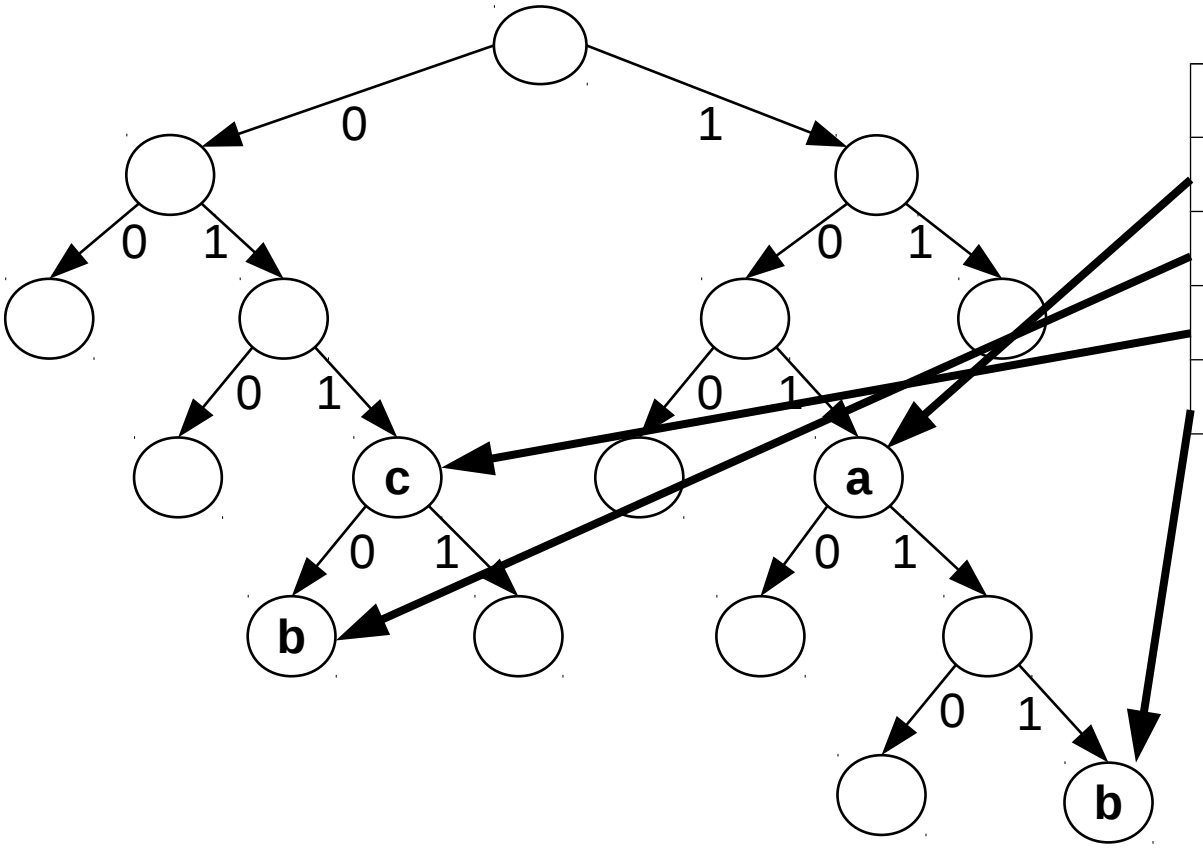

FIB

IP prefix	Prefix	Címke
160.0.0.0/3	101	a
96.0.0.0/4	0110	b
96.0.0.0/3	011	c
184.0.0.0/5	10111	b

Next-hop index

Címke	Next-hop
a	10.0.0.1
b	10.0.0.2
c	10.0.0.3

A prefix fa

- Az üres levélpontokat elhagyhatjuk, az üres pontokba mutató pointerek: NULL
- Kisebb fa, kevesebb memória

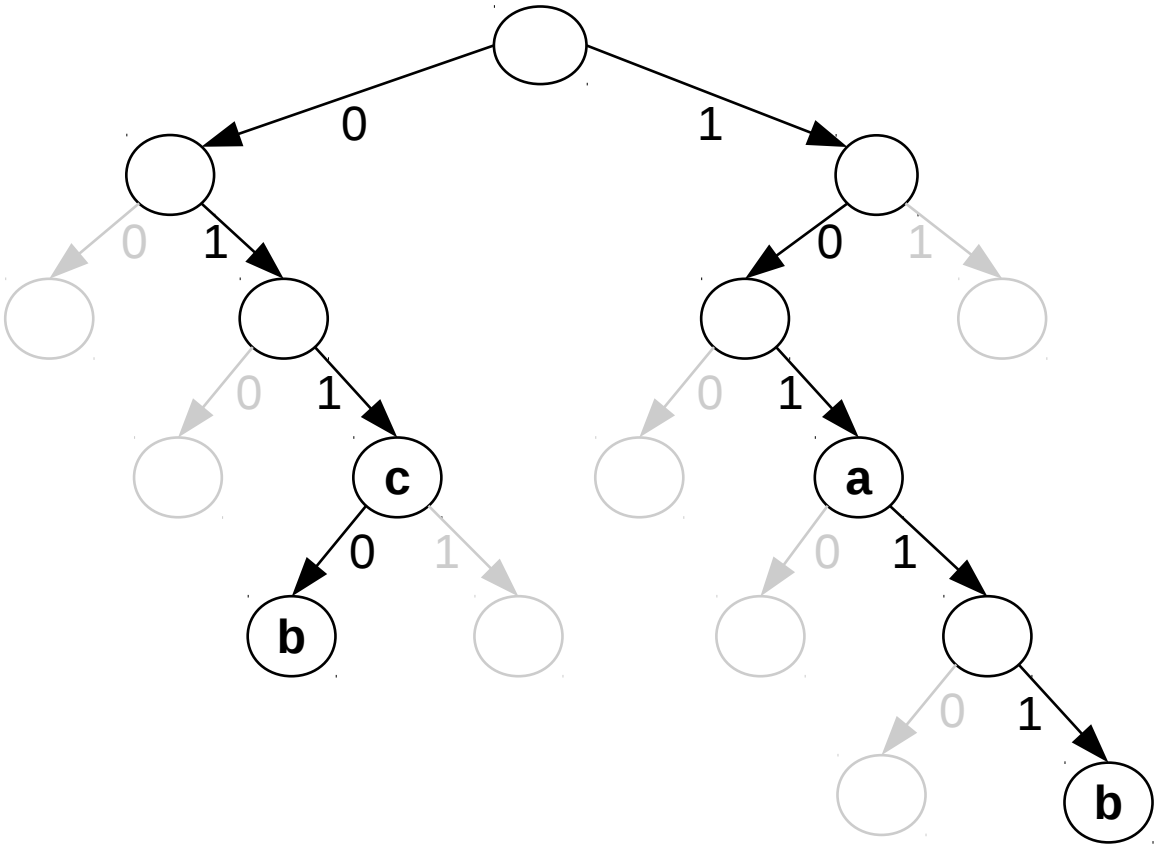

FIB

IP prefix	Prefix	Címke
160.0.0.0/3	101	a
96.0.0.0/4	0110	b
96.0.0.0/3	011	c
184.0.0.0/5	10111	b

Next-hop index

Címke	Next-hop
a	10.0.0.1
b	10.0.0.2
c	10.0.0.3

A prefix fa: keresés

- Keressük a `184.1.1.1=10111...` IP címre a legspecifikusabb találatot a prefix fában
- Start a **gyökérpontból**, **`output←érvénytelen`**

`184.1.1.1=10111...`

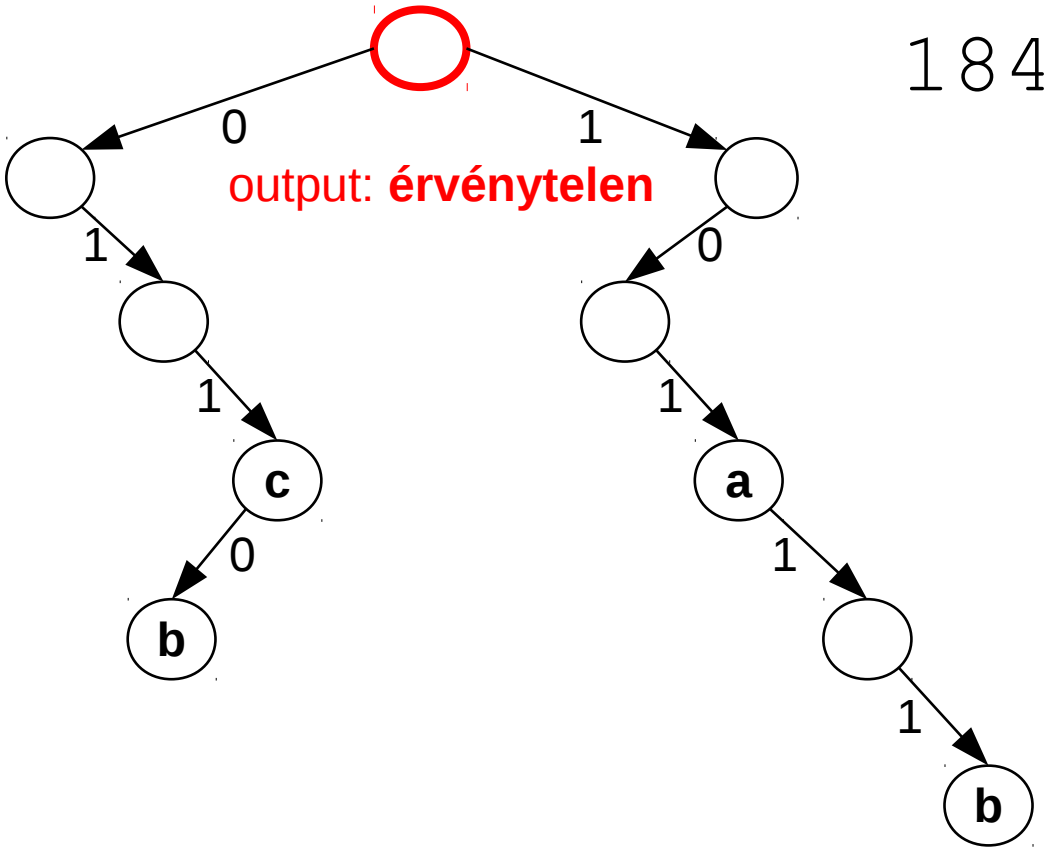

FIB

IP prefix	Prefix	Címke
160.0.0.0/3	101	a
96.0.0.0/4	0110	b
96.0.0.0/3	011	c
184.0.0.0/5	10111	b

A prefix fa: keresés

- A `184.1.1.1=10111...` keresési cím első bitje `1` értékű, így a gyökérből az `1`-es élcímkével ellátott élen lépünk a **következő pontba**

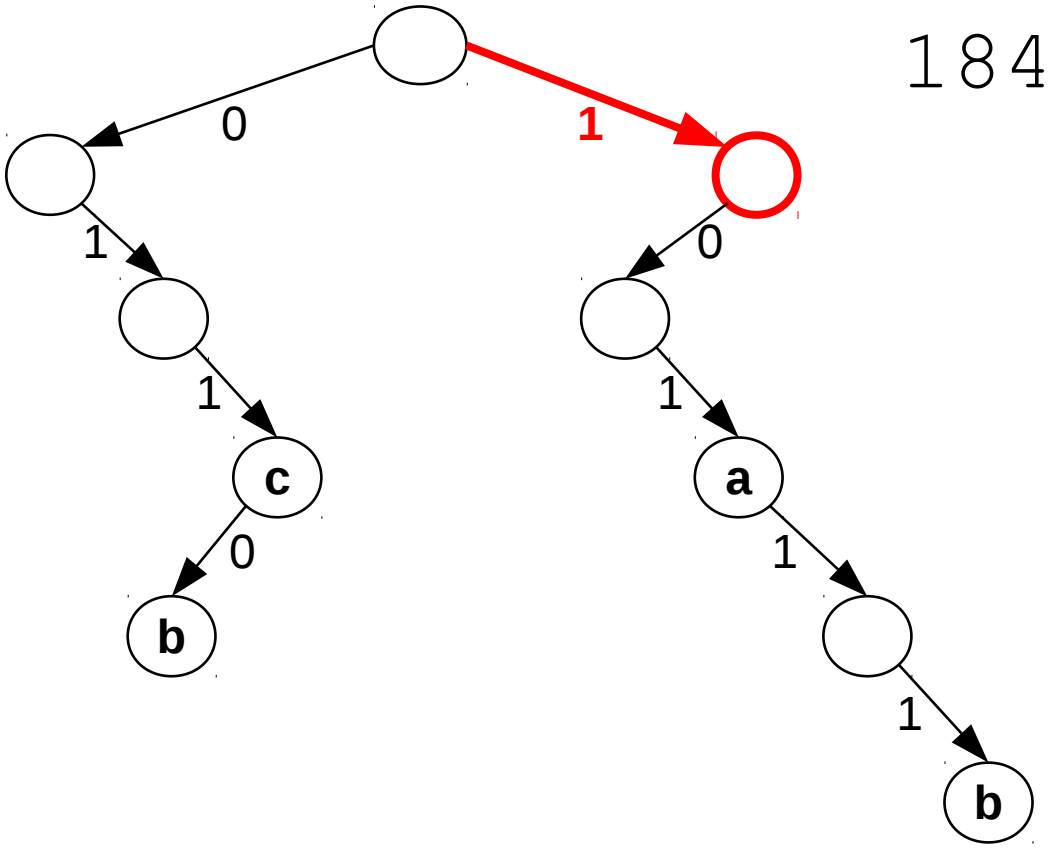

`184.1.1.1=`**`1`**`0111...`

FIB

IP prefix	Prefix	Címke
160.0.0.0/3	101	a
96.0.0.0/4	0110	b
96.0.0.0/3	011	c
184.0.0.0/5	10111	b

A prefix fa: keresés

- Az új pontban nincs címke, output változatlan
- A második bit `0`, így az `0` élcímkén haladunk tovább a **következő pontba**

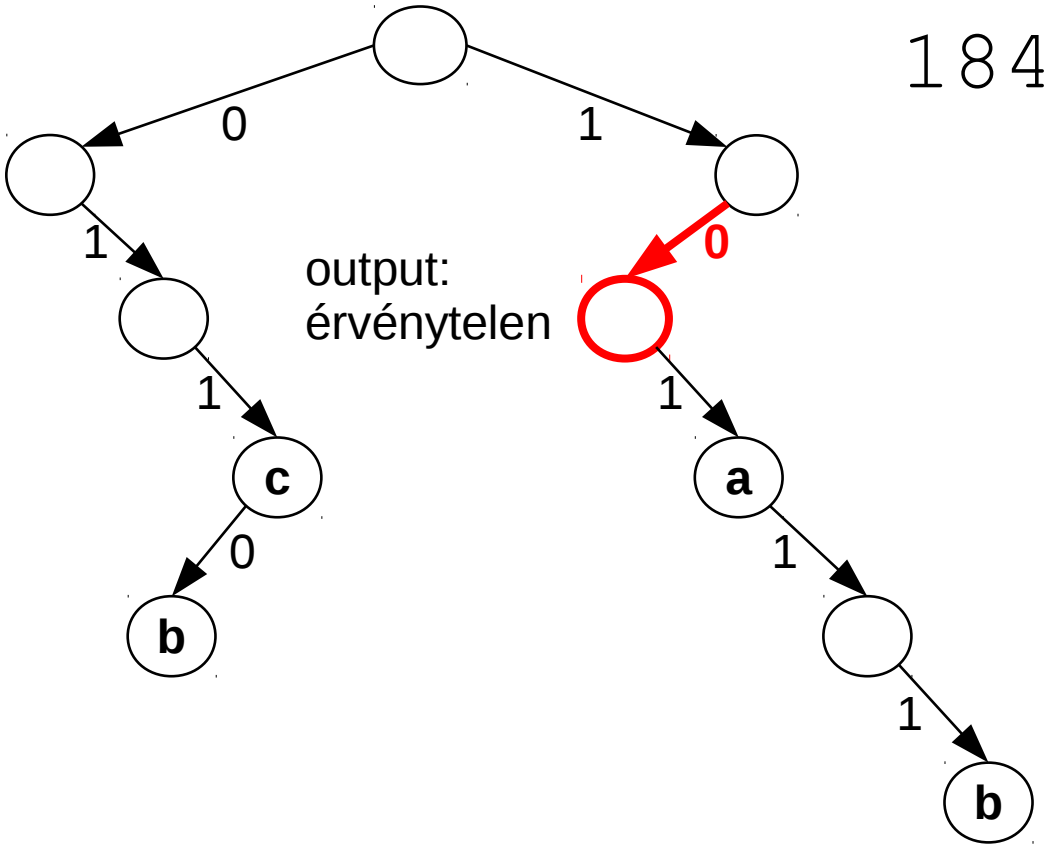

`184.1.1.1=10111...`

FIB

IP prefix	Prefix	Címke
160.0.0.0/3	101	a
96.0.0.0/4	0110	b
96.0.0.0/3	011	c
184.0.0.0/5	10111	b

A prefix fa: keresés

- A harmadik bit ismét `1`, az `1` élcímkén haladunk tob a **következő pontba**
- Az új pont címkéje **a**, ezért: **output ← a**

`184.1.1.1=10111...`

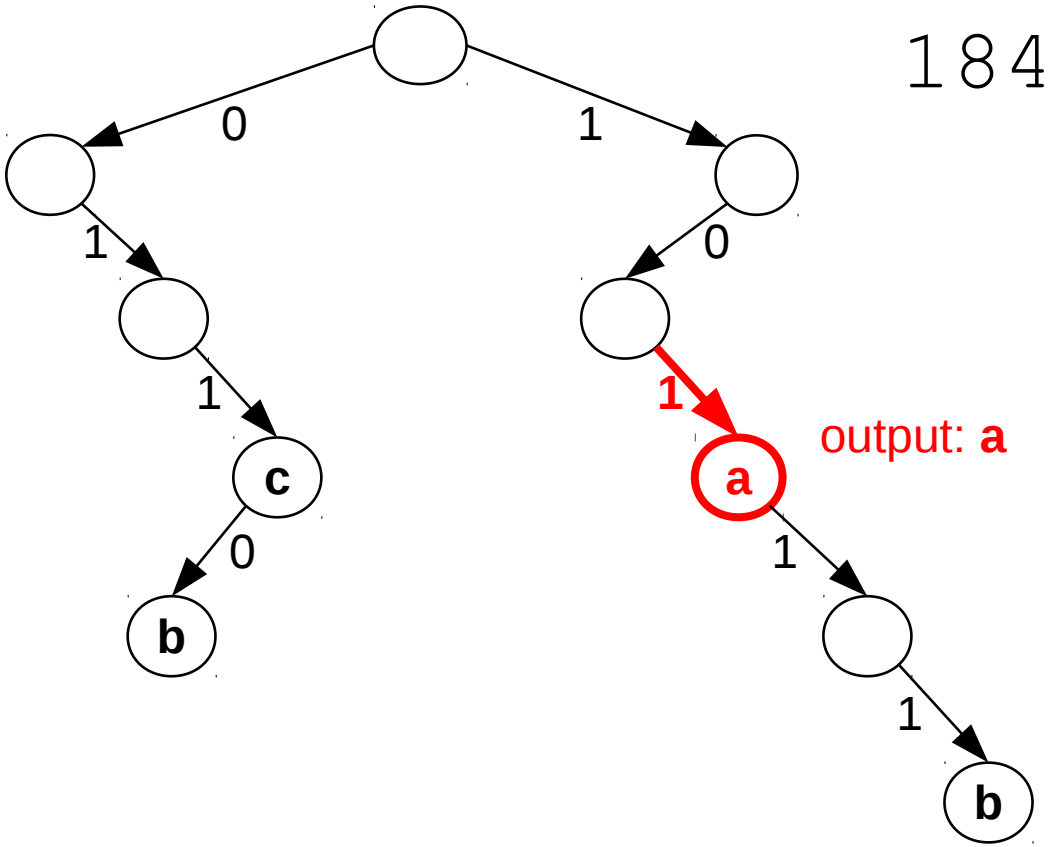

FIB

IP prefix	Prefix	Címke
160.0.0.0/3	**101**	**a**
96.0.0.0/4	0110	b
96.0.0.0/3	011	c
184.0.0.0/5	10111	b

A prefix fa: keresés

- A 4. és 5. bit `11`, az `1` élcímkéken egy **b**, címkével ellátott pontba jutunk, ezért: **output ← b**
- A kapott pont levél, így **kilépés**: **output = b**

`184.1.1.1=10111...`

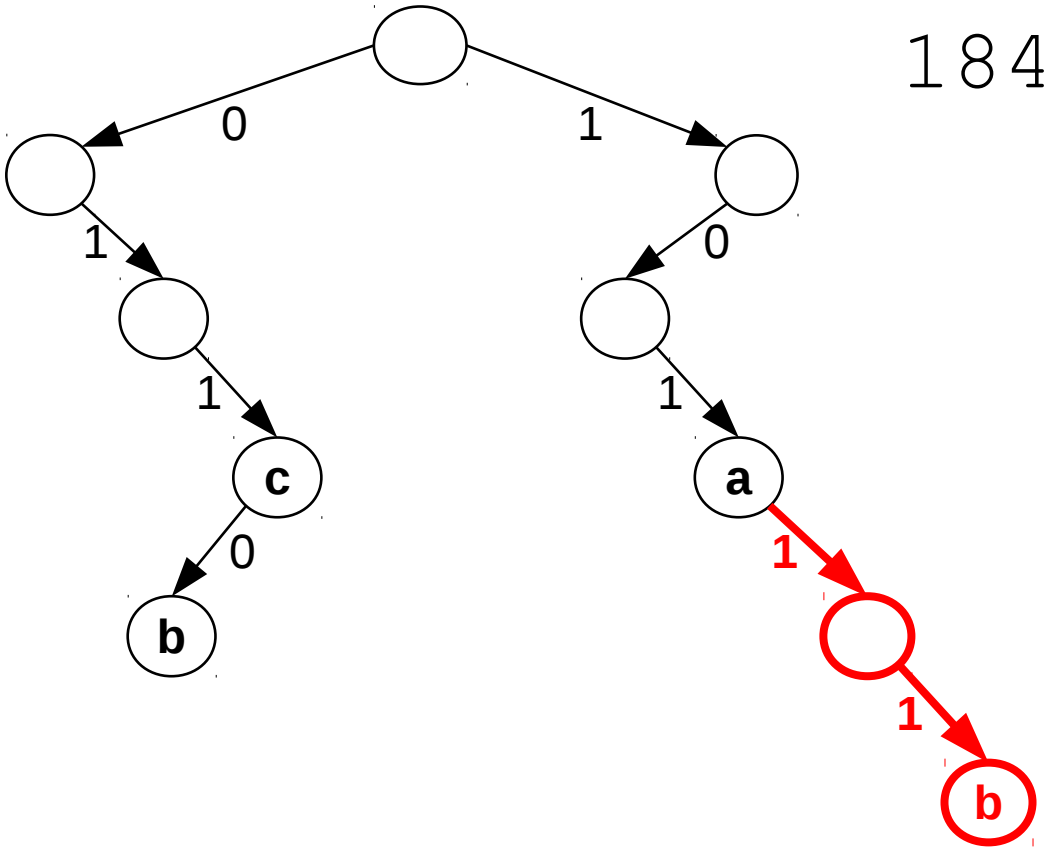

output: **b**

FIB

IP prefix	Prefix	Címke
160.0.0.0/3	101	a
96.0.0.0/4	0110	b
96.0.0.0/3	011	c
184.0.0.0/5	**10111**	**b**

A prefix fa: keresés

- **Algoritmus:** sorban olvassuk a keresett IP cím bitjeit, és az olvasott bitnek megfelelően mindig a `0` vagy `1` élcímkével ellátott élen lépünk tovább egy következő pontba
- Az iteráció közben az output változóban tároljuk a legutoljára olvasott címkét (kezdetben: érvénytelen)
- Ha levélpontot vagy NULL pointert találunk: kilépés
- A kapott címkéhez (output) kiolvasuk a next-hop indexből a megfelelő next-hop címet és visszaadjuk
- Esetünkben az LPM eredmény: `b→10.0.0.2`

A prefix fa: keresés

- LPM a `69.12.75.54=01000...` IP címre
- Nem találkozunk érvényes címkéjű ponttal:
  `output = érvénytelen`

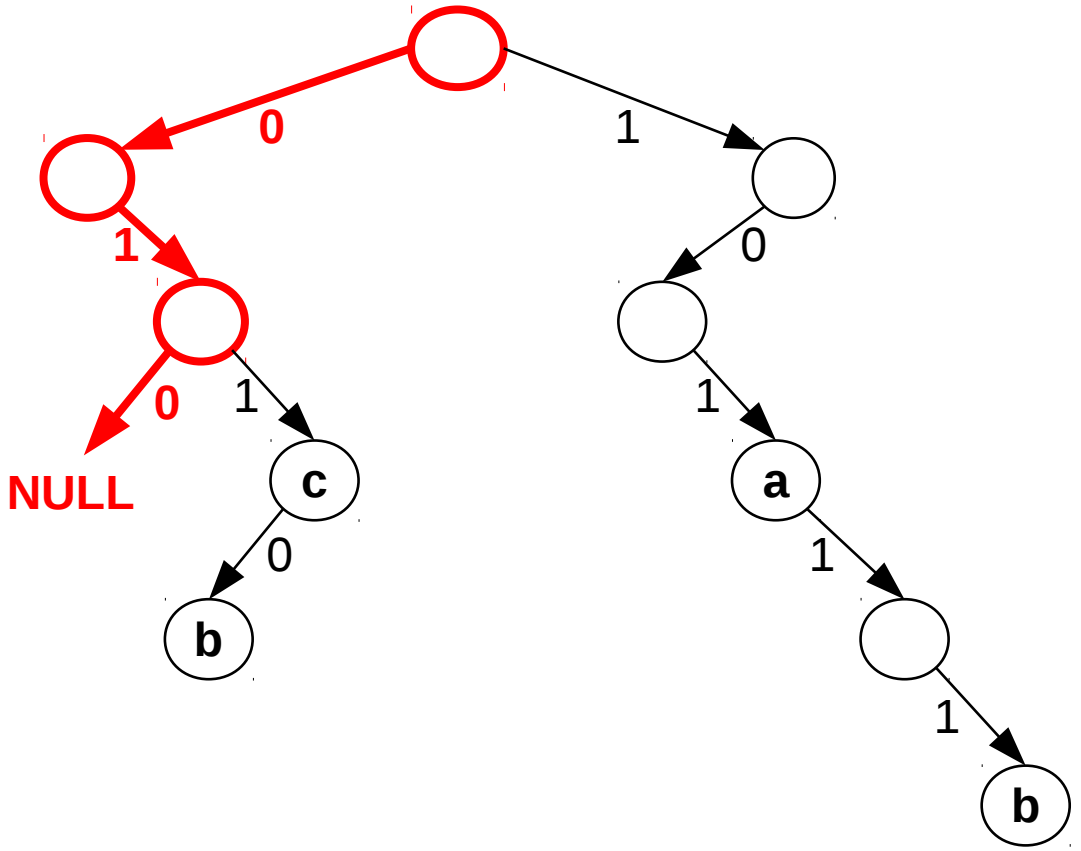

A prefix fa: keresés

- LPM a `178.4.66.19=10110...` IP címre
- Utolsó látott címke: **a**, **`output = a`**

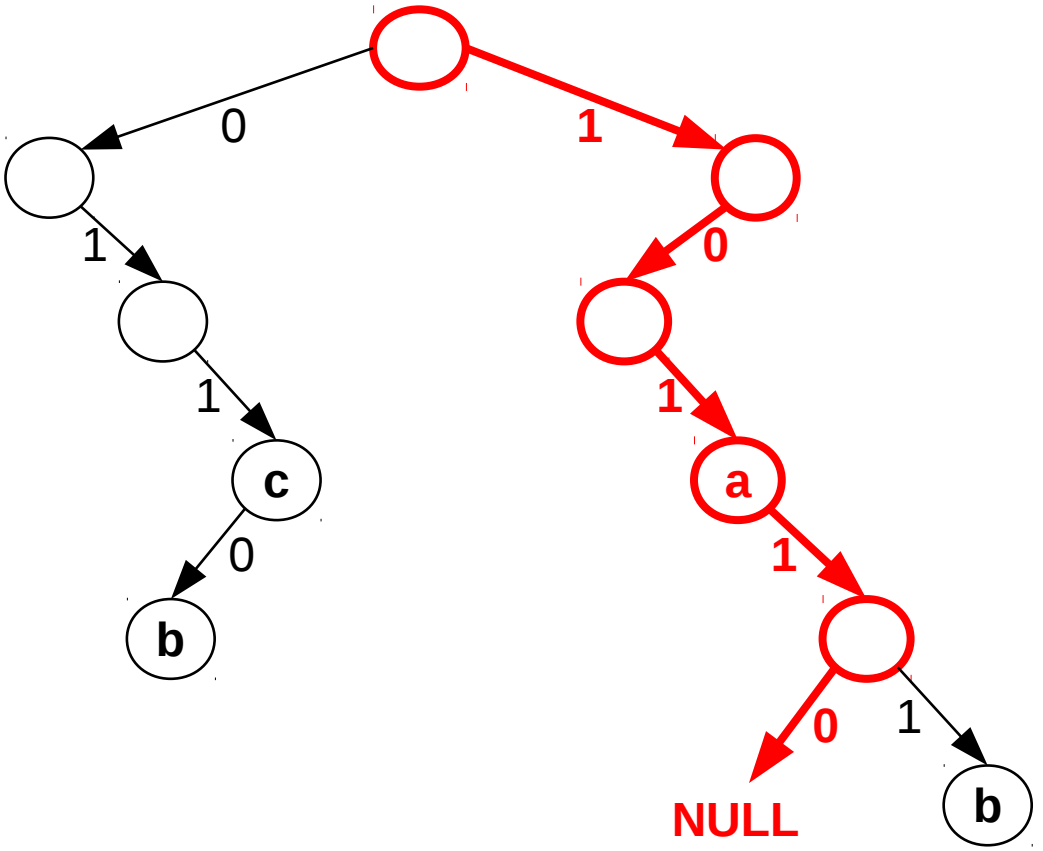

A prefix fa: beillesztés

- Illesszük be a `120.0.0.0/5→10.0.0.3` bejegyzést
- Kövessük a bitek által kijelölt utat, hozzuk létre a hiányzó pontokat, és a kapott pontba írjunk **c**-t

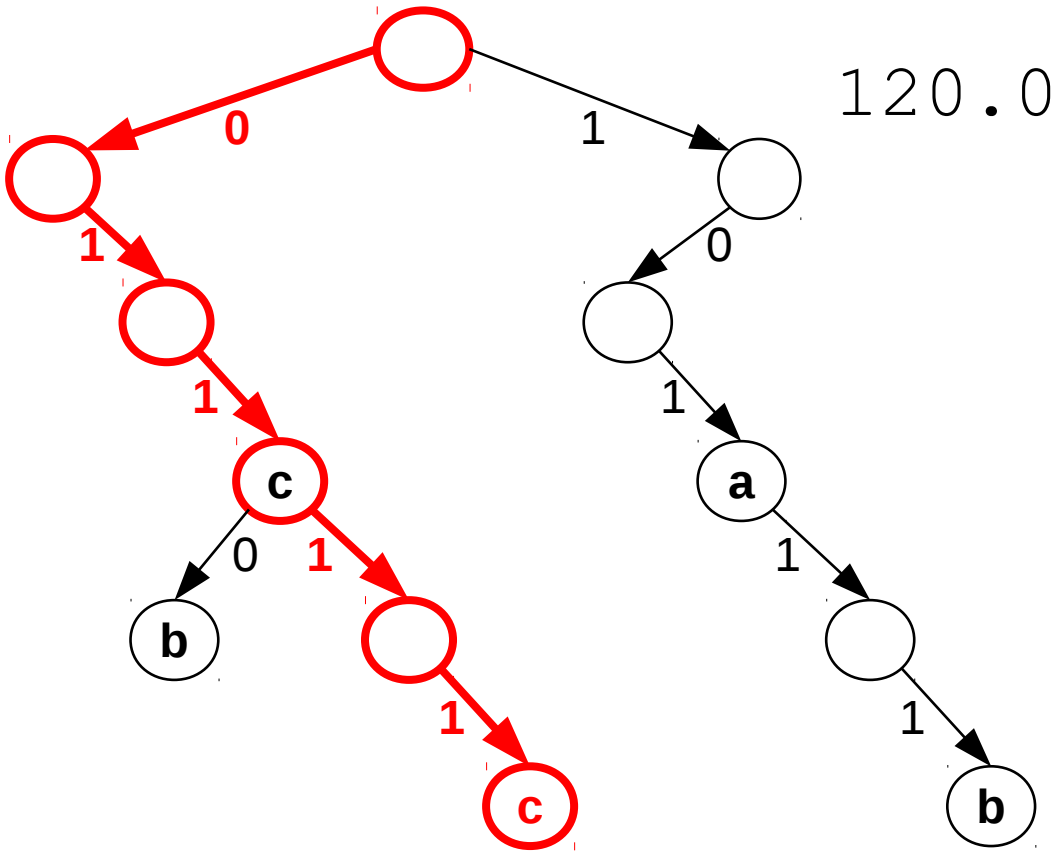

`120.0.0.0/5=01111...`

A prefix fa: egyéb műveletek

- A **módosítás** is hasonló: kövessük a bitek által kijelölt utat, írjuk felül a kapott pontban a címkét
- A **törlés** is hasonló, de kitöröljük a címkét a kapott pontból és felfelé haladva a fán rekurzívan kitöröljük az üres levélpontokat
- Legfeljebb annyi lépést kell tennünk a fában, ahány bitből egy IP cím állhat
- **Tétel:** a prefix fán a LPM keresés, beillesztés, törlés és módosítás, legfeljebb $O(W)$ lépésben végez, ahol W a címtér bitszélessége (IPv4: 32, IPv6: 128)

A prefix fa

- Általánosságban: *N* prefix tárolása esetén a LPM keresés, beillesztés, törlés és módosítás műveletek komplexitása *O(log N)*
- A táblázatos tárolási módszerrel az összes prefixen végig kellene keresni: *O(N)* lépés
- De 32 bit RAM olvasás (főleg ha nem cache-ből történik) időigényes: lassú LPM
- **FIB aggregáció:** a prefix fa konverziója kisebb, de az eredetivel keresés szempontjából teljesen ekvivalens formába
- Feltétel: LPM csak teljesen specifikált IP címekre (32 bit), tetszőleges prefixekre nem feltétlenül működik!

FIB aggregáció

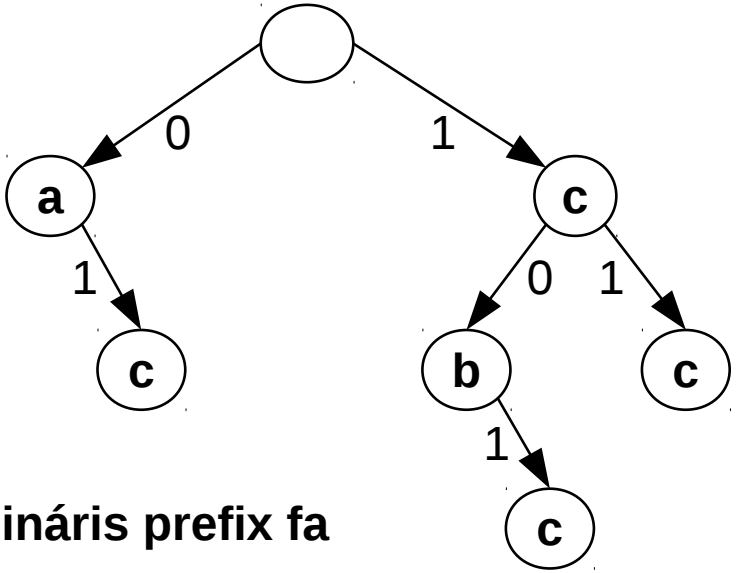

Bináris prefix fa

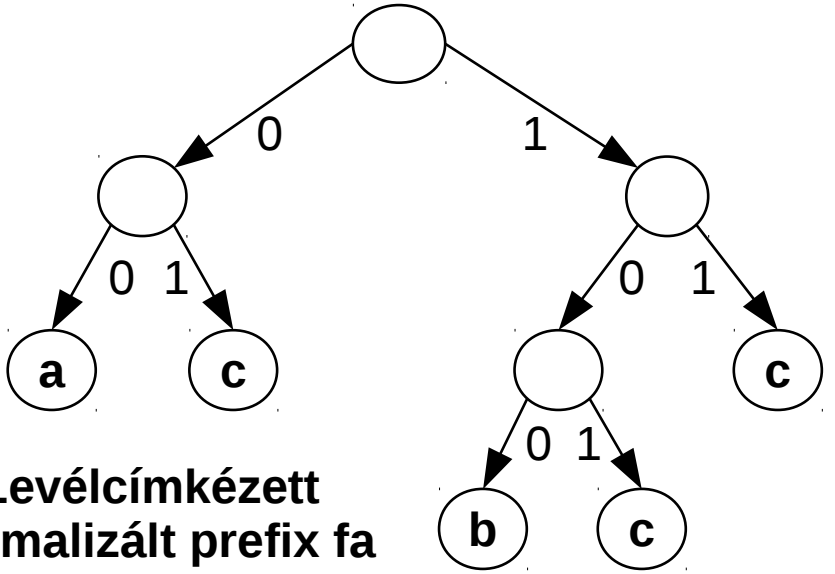

Levélcímkézett normalizált prefix fa

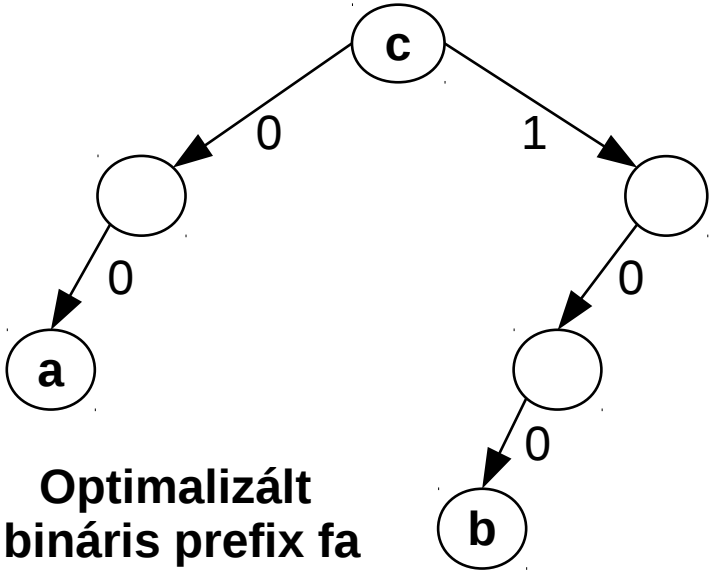

Optimalizált bináris prefix fa

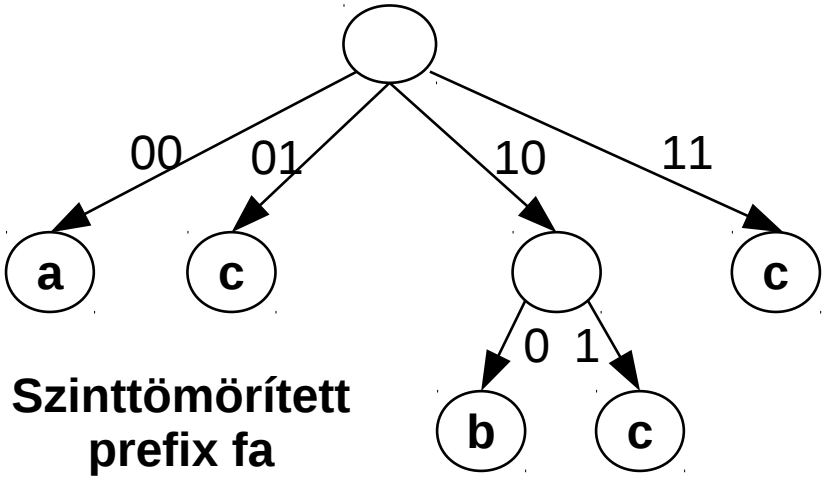

Szinttömörített prefix fa