

Pannon Egyetem

Képfeldolgozás és Neuroszámítógépek Tanszék



Digitális Rendszerek és Számítógép Architektúrák

4. előadás: Aritmetikai egységek - adatkezelés

Előadó: Dr. Szolgay Péter
Vörösházi Zsolt

Jegyzetek, segédanyagok:

- Könyvfejezetek:

- <http://www.knt.vein.hu>

- Oktatás → Tantárgyak → Digitális Rendszerek és Számítógép Architektúrák (Nappali)

- (chapter03.pdf)

- Fóliák, óravázlatok .ppt (.pdf)

- Feltöltésük folyamatosan

Ismétlés

- Korai számítógépek teljesítményét főként ballisztikus számításoknál (hadászatban)
- Információ ábrázolás
- Használt utasításkészlet
- Adatkezelő / műveletvégző egység:
 - Alapvető ALU (Aritmetikai és Logikai funkciók)
 - Aritmetikai operátorok: +, -, *, / (alapműveletek)
 - Logikai operátorok:
NOT, AND, OR, NAND, NOR, XOR (AV), NXOR (EQ)

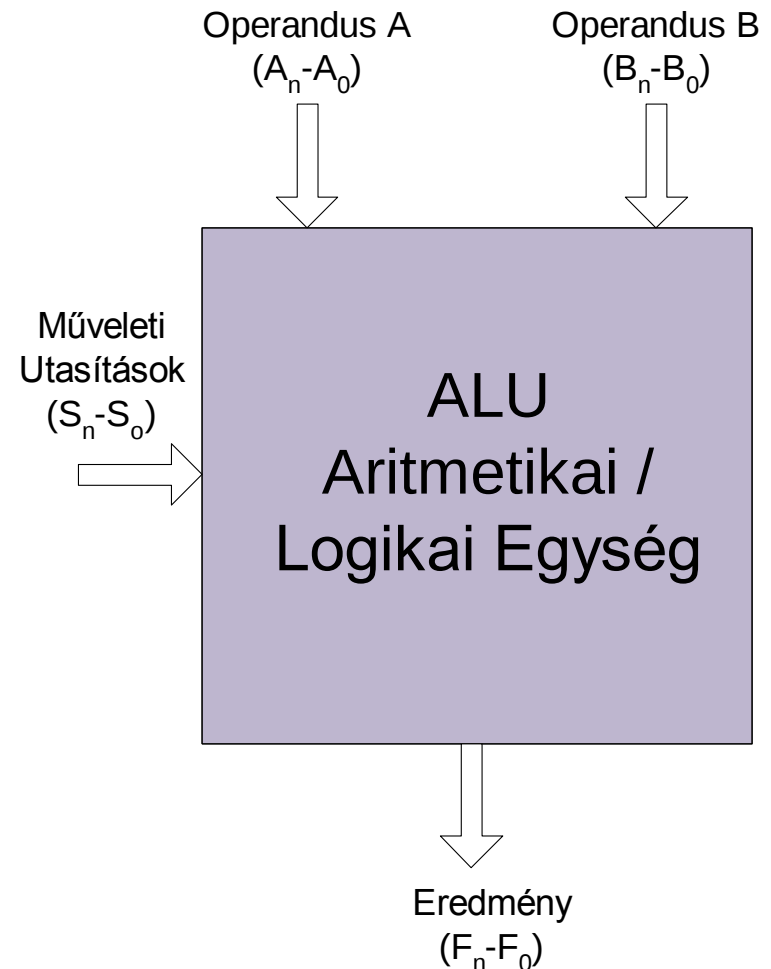
Tervezői célkitűzés

- Komplex funkció megvalósítása minimális kapu felhasználásával
 - Minimális késleltetés legyen az adat-úton
- Univerzálisan teljes leírás (K.H.):
 - NAND illetve,
 - NOR kapuk segítségével minden komplex logikai függvény felírható!
- Aritmetika alapvető építőeleme: összeadó
 - belőle a többi elem ($-$, $*$, $/$) származtatható!

ALU felépítése

- Utasítások hatására a (S_n-S_0) vezérlőjelek kijelölik a végrehajtandó aritmetikai / logikai műveletet. További adatvonalak kapcsolódhatnak közvetlenül a státusz regiszterhez, amely fontos információkat tárol el: pl.


- *zero bit*
- *carry-in, carry-out* átviteleket,
- *előjel* bitet (sign),
- *túlcsordulást* (overflow), vagy *alulcsordulást* (underflow) jelző biteket.




Státusz- (flag) jelzőbitek

- Az aritmetikai műveletek eredményétől függően hibajelzésre használatos jelzőbitek. Ezek megváltozása az utasításkészletben előre definiált utasítások végrehajtásától függ.
 - a.) Előjelbit (sign): 2's komplement (MSB)
 - b.) Átvitel kezelő bit (carry in/out): helyiértékes átvitel
 - c.) Alul / Túlcsordulás jelzőbit (underflow / overflow)
 - d.) Zero bit: kimeneten az eredmény 0-e?


a.) Előjelbit (sign)




b.) Átvitel-kezelő bit (carry)



c.) Zéró bit




d.) Túlcsordulást jelző bit (overflow)



PI: 4-bites ALU felépítése és működése

- Két 4-bites operandus (A, B)
- 4 bites eredmény (F)
- Átvitel: Carry In/ Out
- S2: Aritmetikai/ logikai mód választó (MUX)
- S0, S1: művelet kiválasztó (S2 értékétől függően)




4-bites ALU szimbolikus rajza

ALU működését leíró függvénytáblázat:

Művelet kiválasztás:				Művelet:	Megvalósított függvény:
S2	S1	S0	Cin		
0	0	0	0	$F=A$	‘A’ átvitele
0	0	0	1	$F=A+1$	‘A’ értékének növelése 1-el (increment)
0	0	1	0	$F=A+B$	Összeadás
0	0	1	1	$F=A+B+1$	Összeadás carry figyelembevételével
0	1	0	0	$F = A + \bar{B}$	A + 1’s komplement B
0	1	0	1	$F = A + \bar{B} + 1$	Kivonás
0	1	1	0	$F=A-1$	‘A’ értékének csökkentése 1-el (decrement)
0	1	1	1	$F=A$	‘A’ átvitele
1	0	0	0	$F = A \wedge B$	AND
1	0	1	0	$F = A \vee B$	OR
1	1	0	0	$F = A \oplus B$	XOR
1	1	1	0	$F = \bar{A}$	‘A’ negáltja (NOT A)

ALU felépítése:





Lebegőpontos műveletvégző egységek

Lebegőpontos műveletvégző egységek

■ Probléma:

- Mantissa igazítás → Exponens beállítás
- Normalizálás (DEC-32, IEEE-32, IBM-32)


■ Műveletvégző elemek:

- Összeadó-,
- Kivonó-,
- Szorzó-,
- Osztó áramkörök.

a.) Lebegőpontos összeadó

■ Művelet: $A = M_B \times r^{E_B} + M_C \times r^{E_C} = (M_B \times r^{E_B - E_C} + M_C) \times r^{E_C}$


- Komplex feladat: a mantisszák hosszát egyeztetni kell (MSB bitek azonos helyiértéken legyenek)
- Legyen: $0 < B < C$
- $B \rightarrow C$ vagyis $|E_B - E_C|$ vel jobbra igazítjuk a mantisszát; ez változás az exponensben is
- Összeadás: sign-magnitude formátum!
- Végül minimális post-normalizáció kell



b.) Lebegőpontos kivonó

■ **Művelet:** $A = M_B \times r^{E_B} - M_C \times r^{E_C} = (M_B \times r^{|E_B - E_C|} - M_C) \times r^{E_C}$

- Komplex feladat: a mantisszák hosszát egyeztetni kell (MSB bitek azonos helyiértéken legyenek)
- Legyen: $0 < B < C$
- $B \rightarrow C$ vagyis $|E_B - E_C|$ vel jobbra igazítjuk a mantisszát, ez változás az exponensben is
- Kivonás! (ALU)



c.) Lebegőpontos szorzó

■ Művelet: $A = B \times C = M_B \times r^{E_B} \times M_C \times r^{E_C} = (M_B \times M_C) \times r^{E_B + E_C}$

□ A: szorzat


□ B: szorzandó

□ C: szorzó

□ Könnyű végrehajtani

□ Nincs szükség az operandusok beállítására

□ Minimális post-normalizációt kell csak végezni



d.) Lebegőpontos osztó

■ Művelet: $A = B / C = M_B \times r^{E_B} / M_C \times r^{E_C} = (M_B / M_C) \times r^{E_B - E_C}$

□ A: hányados

□ B: osztandó


□ C: osztó

□ Könnyű végrehajtani

□ Nincs szükség az operandusok beállítására

□ Minimális post-normalizációt kell csak végezni

□ Osztás! (ALU)





Összeadó / Kivonó áramkörök


a.) Teljes összeadó – Full Adder

■ FA: 1-bites Full Adder


igazságtáblázat

A_i	B_i	C_{in}	Sum_i	C_{out}
0	0	0	0	0
0	0	1	1	0
0	1	0	1	0
0	1	1	0	1
1	0	0	1	0
1	0	1	0	1
1	1	0	0	1
1	1	1	1	1

szimbólum



A FA egy CMOS kapcsolási rajza:



Karnaugh táblái:

		C			
		B		A	
C_{out}	A	00	01	11	10
	0	0	0	1	0
A	1	0	1	1	1

Kimeneti fgv-ei:


$$C_{out} = A \cdot B + A \cdot C_{in} + B \cdot C_{in}$$

		C			
		B		A	
S_i	A	00	01	11	10
	0	0	1	0	1
A	1	1	0	1	0

$$S_i = A_i \oplus B_i \oplus C_{in}$$

b.) Átvitelkezelő összeadó – Ripple Carry Adder (RCA)

- Pl. 6-bites RCA: [0..5] (LSB Cin = GND!)



- Számítási időszükséglet (RCA):

$$T_{(RCA)} = N \cdot T_{(FA)} = N \cdot (2 \cdot G) = 12 G \text{ (pl. 6-bites RCA esetén)}$$

ahol a 2G az 1-bites FA kapukésleltetése. Lassú carry terjedés.


c.) LACA: Look Ahead Carry Adder:

■ Képlet (FA) átírásából kapjuk:

$$C_{out} = A_i \cdot B_i + A_i \cdot C_{in} + B_i \cdot C_{in}$$

$$\Rightarrow \underbrace{A_i \cdot B_i}_{\text{CarryGenerate}} + C_{in} \cdot \underbrace{(A_i + B_i)}_{\text{CarryPropagate}} = C_G + C_{in} \cdot C_P$$

$$S_i = A_i \oplus B_i \oplus C_{in}$$




LACG: Look Ahead Carry Generator áll egy **b** bites ALU-ból, mindenegyes állapotban a Carry generálásáért felel a CP és CG (LACA) vonalakon érkező jeleknek megfelelően.

LACA számítási időszükséglete: $T_{LACA} = 2 + 4 \times (\lceil \log_b(N) \rceil - 1)$

ahol N: bitek száma, b: LACG bitszélessége (hány LACA-ból áll egy LACG)

Példa: 4-bites LACA

- Legyen $b=4$, és $N=4$. Áramkör felépítése, és időszükséglete?



$$T_{LACA} = 2 + 4 \times (\underbrace{(\lceil \log_4(4) \rceil - 1)}_1) = 2$$


d.) Teljes kivonó - Full Subtractor (FS)

■ FS: 1-bites Full Subtractor


igazságtáblázat

X_i	Y_i	B_{in}	F_i	B_{out}
0	0	0	0	0
0	0	1	1	1
0	1	0	1	1
0	1	1	0	1
1	0	0	1	0
1	0	1	0	0
1	1	0	0	0
1	1	1	1	1

szimbólum



Logikai kapcsolási rajz (B out-ra)



Karnaugh táblái:

B_{out} :

X_i	Y_i	B_{in}			
		00	01	11	10
0	0	0	1	1	1
1	0	0	0	1	0

Kimeneti fgv-ei:

$$B_{out} = \overline{X_i} \cdot Y_i + \overline{X_i} \cdot B_{in} + Y_i \cdot B_{in}$$

F_i :

X_i	Y_i	B_{in}			
		00	01	11	10
0	0	0	1	0	1
1	0	1	0	1	0

$$F_i = X_i \oplus Y_i \oplus B_{in}$$

Szorzó áramkörök

- I. Iteratív szorzási módszerek
- II. Közvetlen szorzási módszerek



I.) Iteratív szorzási módszerek

Iteratív szorzási módszerek alapjai

■ Tényezők:

$$P = A \times B$$

- P: szorzat, A:szorzandó, B:szorzó

□ Pl: Legyenek:

- 'A' és 'B' 5-bites számok $(0 \dots 2^5 - 1) = 0 \dots 31$
- Maximálisan $P = 31 \times 31 = 961$ lehet (10 bites)

■ Tehát: N bites számok szorzatát $2 \times N$ biten tudjuk eltárolni!

$$P = A \times B = A \times B_4 B_3 B_2 B_1 B_0 =$$

$$= A \times B_4 \times 2^4 + A \times B_3 \times 2^3 + A \times B_2 \times 2^2 + A \times B_1 \times 2^1 + A \times B_0 \times 2^0$$

Iteratív szorzási műveletek:

■ Hagyományos (Shift&Add) módszer (LSB→MSB)

	x	A4 B4	A3 B3	A2 B2	A1 B1	A0 B0
PP0		A4*B0	A3*B0	A2*B0	A1*B0	A0*B0
PP1		A4*B1	A3*B1	A2*B1	A1*B1	A0*B1
PP2			A4*B2	A3*B2	A2*B2	A1*B2
PP3		A4*B3	A3*B3	A2*B3	A1*B3	A0*B3
PP4	A4*B4	A3*B4	A2*B4	A1*B4	A0*B4	
PR	az egyes oszlopok összege					


■ Fordított sorrendű (MSB → LSB):

	x	A4 B4	A3 B3	A2 B2	A1 B1	A0 B0
PP0		A4*B4	A3*B4	A2*B4	A1*B4	A0*B4
PP1			A4*B3	A3*B3	A2*B3	A1*B3
PP2				A4*B2	A3*B2	A2*B2
PP3					A4*B1	A3*B1
PP4						A4*B0
PR	az egyes oszlopok összege					


1.) Általános Shift&Add módszer

- $P=A \times B$ (A:szorzandó, B:szorzó)
- Parciális szorzat (P_{Pi}) összegeket az LSB $\rightarrow$ MSB bitek felől képzí (mivel a B szorzat biteket is ebben a sorrendben tölti be)
- AND kapuk: P_{Pi} -k képzése
- Shiftelés: *Huzalozott eltolással* (a visszacsatolt ágban)

Példa: két 8-bites szám Shift&Add módszerű szorzására



Időzítési jelek:




- A MIER_CLK-H (B): magas-aktív órajel vezérli a bemeneti 165'-ös SHIFT (paralel in- serial out) regisztert
- MIER_LD-L: load jel hatására, képes az összes bemenetére érkező jelet egy lépésben betölteni
- A PROD_CLK-H: magas-aktív órajel (273' D tárolókból álló regiszternél)
- PROD_CLR-L: törlőjel, amely hozzáadás előtt törli a 273' regiszterek tartalmát

Folyamatábra (Shift-add)


- Alapvetően adatfüggetlen, DE:
- Adatfüggővé tehető - gyorsítható algoritmus!

□ Bemenő (A,B) értékek figyelését kell megoldani: zérus-e?



2.) Fordított sorrendű módszer

- $P=A \times B$ (A:szorzandó, B:szorzó)
- Parciális szorzat (PP_i) összegeket itt fordított sorrendben, az MSB $\rightarrow$ LSB bitek felé haladva képzik (a B szorzat biteket fordított sorrendben töltik be)
- Bemenetek figyelése: ha a szorzandó, vagy szorzó bitek értéke zérus, leegyszerűsödik a művelet. (AND kapukkal)



Példa: két 8-bites szám Fordított sorrendű szorzására

Az `AND_BIT_H` jel ellenőrzi, hogy az „A” szorzandó regiszter hozzáadható-e a „B” szorzóregiszterhez, és az eredmény betölthető-e a „P” szorzatregiszterbe.

Ha az `MSB='1'`, akkor betehető, ha '0' akkor a szorzó és szorzandóregiszter 1 bitpozícióval shift-elődik.

Folyamatábra (fordított sorrendű)


- Adatfüggő algoritmus - gyorsított végrehajtás
 - Bemenő (A,B) értékeket figyeli, hogy zérus-e?

- Időszükséglet:

$$T_{Mult} = T_{Setup} + N \times T_{Iter} \quad \text{ahol}$$

$$T_{Iter} = T_{AND} + T_{Sum} + T_{Reg}$$

- T(SETUP): kezdeti ellenőrzések, inicializálás ill. szorzat regiszter törlése
- T(AND): AND függvények végrehajtása, parciális szorzatok képzése
- T(SUM): parciális szorzatok összeadása
- T(REG): betöltésük a regiszterbe



c.) Előjeles szorzás Booth-algoritmussal:

■ *Negatív számokkal* is lehet szorzást végezni!

□ Legyen a következő B 2's komplement 6-bites szám

$$\square B = B_5 B_4 B_3 B_2 B_1 B_0 = B_5 \times (-2^5) + B_4 \times 2^4 + B_3 \times 2^3 + B_2 \times 2^2 + B_1 \times 2^1 + B_0 \times 1.$$

□ **Újrakódolási technika (séma):**

$$B(2' \text{ komplement}) = B_5 \times (-32) + B_4 \times 16 + B_3 \times 8 + B_2 \times 4 + B_1 \times 2 + B_0 \times 1 =$$

TRÜKK!!

$$= B_5 \times (-32) + B_4 \times (32 - 16) + B_3 \times (16 - 8) + B_2 \times (8 - 4) + B_1 \times (4 - 2) + B_0 \times (2 - 1) =$$

(azonos numerikus értékek összerendelése)

$$= B_5 \times (-32) + B_4 \times 32 - B_4 \times 16 + B_3 \times 16 - B_3 \times 8 + B_2 \times 8 - B_2 \times 4 + B_1 \times 4 - B_1 \times 2 + B_0 \times 2 - B_0 \times 1 =$$

$$= -32 \times (B_5 - B_4) - 16 \times (B_4 - B_3) - 8 \times (B_3 - B_2) - 4 \times (B_2 - B_1) - 2 \times (B_1 - B_0) - 1 \times (B_0 - 0).$$

Példa: előjeles Booth algoritmus

- Az előző oldalon lévő *átzárójelezéssel* a megfelelő értékeket két bitpár kivonásával kapjuk (a **zárójeles** kifejezés értéke ha **+**:akkor kivonás,/ ha **0**:akkor áteresztés / ha **-** összeadás történik). A súlytényezők 2 hatványai, és a szorzást a súlytényezők shiftelésével oldják meg ('165 Shift-regiszterrel). Egy összeadást mindig egy kivonás követ alternáló jelleggel.

- Példa: 543210 (bitpozíciók)

011001= 25 „A”

101101=-19 „B”

Végrehajtjuk **A*B**-t!

Az újrakódolást bitpárokon végezzük el:

$$-1 \times (B_0 - 0) = \underline{-1}$$

$$C_0 = 0 - 1 \times A$$

Mivel - volt az érték, ezért kivonjuk a 0-ból az A-t.

$$-2 \times (B_1 - B_0) = \underline{+2}$$

$$C_1 = C_0 + 2 \times A$$

Mivel + volt az érték, ezért hozzáadjuk C0-hoz a 2*A-t.

$$-4 \times (B_2 - B_1) = \underline{-4}$$

$$C_2 = C_1 - 4 \times A$$

kivonjuk

$$-8 \times (B_3 - B_2) = \underline{0}$$

$$C_3 = C_2$$

Mivel '0' volt, Áteresztés, nem változik.

$$-16 \times (B_4 - B_3) = \underline{+16}$$

$$C_4 = C_3 + 16 \times A$$

hozzáadjuk


$$-32 \times (B_5 - B_4) = \underline{-32}$$

$$C_5 = C_4 - 32 \times A$$

kivonjuk

Példa: két 8-bites szám Booth alg. szorzására

A '74 D tároló kimenetéről B0_H ill. a „B” szorzóregiszter kimenetéről B1_H jelek a szorzó shiftelődésének megfelelően generálódnak. Ezek állítják elő megfelelő kombinációs hálózat (2 NAND kapu, és 1 Inverter) segítségével az S0-S3 kiválasztó jeleket az ALU-nál.






II. Közvetlen szorzási módszerek

Közvetlen szorzási módszerek

- Először a részlet-szorzatokat (Partial Products: PPI) állítjuk elő, amelyeket összeadunk. A részlet-szorzatok eltolását egységnyi kapu késleltetéssel lehet megoldani.
- Fajtái (részlet-szorzat képzés):
 - ☐ Lineáris modell,
 - ☐ Fa modell,
 - ☐ Full Adder felhasználásával,
 - ☐ CSA: Carry Save Adder,
 - ☐ Sorcsökkentős megvalósítás (row reduction).


a.) Lineáris modell

- A parciális szorzatképzés után azonnal összeadhatók, így gyorsabban megkapjuk az eredményt. N bites számok esetén (N-1) db összeadóra van szükségünk. Lassabb, mint a következő FA modell, mivel több összeadó szintű a késleltetés.
- Időszükséglet: $T_{\text{(DIRECT-LINE)}} = (N-1) * T_{\text{(SUM)}}$



b.) Fa modell

- A parciális szorzatok, képzésük után szintén azonnal összeadhatók, gyorsabban megkapjuk az eredményt, mint a lineáris modellnél, mivel ebben az esetben (N=8 bit esetén) csak 3 szintű a hierarchia, így kevesebb a késleltetés. N bites számok esetén (N-1) db összeadóra van szükségünk.
- Időszükséglet: $T_{DIRECT-TREE} = \lceil \log_2(N) \rceil * T_{SUM}$




c.) Full Adder-es megvalósítás

- A mellékelt ábra két 4 bites szám szorzását valósítja meg. A sorokat, mint parciális szorzat tömböket emeljük ki. Jel: $R_{x,y}$, ahol x a sor száma, y a sor eleme (oszlop).

$P = A \times B$

			(A3	A2	A1	A0)	
			(B3	B2	B1	B0)	
				R 0,3	R 0,2	R 0,1	R 0,0 PP0
		R 1,3	R 1,2	R 1,1	R 1,0		PP1
	R 2,3	R 2,2	R 2,1	R 2,0			PP2
R 3,3	R 3,2	R 3,1	R 3,0				PP3
P7	P6	P5	P4	P3	P2	P1	P0




d.) CSA: Carry Save Adder

•CSA: olyan Full Adder, amely az előző szint átvitelét (Cout) eltárolja, és a következő szint Cin-jének továbbítja. Ezzel a módszerrel a szorzás tovább gyorsítható. A késleltetés mindig $2G$.

•Az utolsó sorban FA-kat használunk, míg az első két sorban CSA-k találhatók. A CSA csökkenti az összeadandó sorok számát (3-2 sorcsökkentő egységnek felel meg).

$P=A \times B$

	(A3	A2	A1	A0)	
	(B3	B2	B1	B0)	
		R 0,3	R 0,2	R 0,1	R 0,0
					PP0
	R 1,3	R 1,2	R 1,1	R 1,0	
					PP1
	R 2,3	R 2,2	R 2,1	R 2,0	
					PP2
	R 3,3	R 3,2	R 3,1	R 3,0	
					PP3
P7	P6	P5	P4	P3	P2
P1	P0				




e.) Sorcsökkentős megvalósítás (row reduction)

- Példa: Két $N=56$ bites számot szeretnénk összeszorozni ezzel a megoldással (eredmény $P=2*N=112$ bites lesz).
- Sorcsökkentő: Egy „ k ” kimenetű sorcsökkentő egység $0 - 2^k-1$ értéket tud reprezentálni, ezért 2^k-1 bemenetet tud kezelni. Így definiálhatók 31-5, 15-4, 7-3, 3-2 sorcsökkentő egységek. Nagy előnyük, hogy a *parciális részletszorzatok* (PPI) összeadását párhuzamosan végzik. Így egy N bites bemenetet végül 2 bitesre tudunk redukálni, amely után egy egyszerű PI. teljes összeadó (FA) vagy LACA összeadó használható.
- Most 56×56 bites szorzást végzünk: egy megkötésünk, hogy a legnagyobb alkalmazható sorcsökkentő egység 15-4. Az utolsó előtti 3-2 sorcsökkentő egység a carry save adder (CSA), amelyet végül egy LACA (tekintsük egy $b=8$ bites CP-t propagáló és CG-t generáló LACG egységnek), amelyik a $2*56=112$ bites eredményt számolja ki. Így LACA számítási szükséglete a következő:

$$T_{LACA} = 2 + 4 \times (\lceil \log_8(112) \rceil - 1) = 2 + 4 \times (3 - 1) = 10G$$

e.) Sorcsökkentős megvalósítás (row reduction) /folytatás/

Ha mindenegyedű sorcsökkentőnek $2G$ a késleltetése, amelyet beszorzunk a szintek számával akkor $8G$ -t kapunk. Ehhez hozzájön, az inputot terhelő $1G$ késleltetés. Így összesen $9G+10G=\underline{19G}$ a kapukésleltetése az eszköznek, ezzel a sorcsökkentős megoldással.





Osztó áramkörök

Osztó áramkörök:


- I.) Hagyományos közvetlen osztási algoritmus
- II.) Iteratív osztási algoritmusok

I.) Hagyományos közvetlen osztási algoritmus:

Ez az osztási folyamat igen lassú eljárás. Lépései:

1. az *osztót* a D_s regiszterbe rakjuk, az *osztandót* a Q regiszterbe.
2. töröljük az R regisztert
3. iterációs lépés: kivonjuk az R -ből a D_s osztót. Ha $R - D_s > 0$ akkor folytatódik, tehát ezt a megváltozott értéket visszatesszük az R -be, és egy '1'-est teszünk a Q regiszterbe. Ha $R - D_s < 0$ akkor R regiszter tartalma nem változik, és egy '0'-át teszünk a Q regiszterbe (vagy hogyha nincs több osztandó bit, akkor vége az osztásnak).
4. Minden iterációs lépésben egy-egy új bit jön létre, amelyet a Q regiszterbe shiftelünk, ahogyan az R regiszterbe az osztandót
5. Az osztandó legnagyobb helyiértékű (MSB) bitjével kezdjük az összehasonlítást (míg a legkisebbtől a legnagyobb helyiértékek felé, balra haladva shiftelünk a visszaszorzásnál)
6. A hányados generálódik elsőként az MSB felől, és a Q -ba shiftelődik 1 bittel balra
7. A folyamat végén a maradék az R -ben, a hányados pedig a Q -ban lesz

$$D_d = Q \times D_s + R$$



Példa: Hagyományos osztási algoritmus

$$Dd = Q * Ds + R$$

Egy kikötésünk van: $R < Ds$ esetén leáll az osztás!

Decimális számok esetén:

5 | 8 : 5 = 1 | 1

0 8


3

Bináris számok esetén hasonlóan


1011

Q hányados (Ds hányszor van meg Dd-ben)


111010 101/ 111 010 101 ↓ 10 ↓ 100 00 000 100 1001 0 101 100 1000 101 11	Dd osztandó Ds osztó 111-ben megvan „101” ezért 1? Q Visszaszorzás 1*„101”-el Ez a kivonás eredménye 111-101=10 100-ban nincs meg az '101', ezért 0? Q Visszaszorzás 0*„101”-el Ez a kivonás eredménye 100-000=100 1001-ban megvan '101', ezért 1? Q Visszaszorzás 1*„101”-el Ez a kivonás eredménye: 1001-101=100 1000-ban megvan az '101', ezért 1? Q Visszaszorzás 1*„101”-el Kivonás eredménye: 1000-101=11 Ez a maradék R!
--	--



Hagyományos osztó áramkör



Folyamatábra: osztási algoritmus



II.) Iteratív osztási algoritmus

- a.) Gyors osztás Newton- Raphson módszerrel
- b.) Közvetlen gyors osztó

a.) Gyors osztás Newton- Raphson módszerrel

Az előzőnél gyorsabb osztási művelet reciprokképzéssel valósul meg. Szorzó segítségével végezzük el az osztást. A Newton-Raphson iteráció alapformulája a következő:

$$x_{i+1} = x_i - \frac{f(x_i)}{f'(x_i)}$$


Van egy megfelelő f függvényünk és egy x_0 kezdeti értékünk. Iterációs lépésekkel megkapjuk az osztás eredményét az $f(x)=0$ egyenlet megoldásaként. Az f -et úgy kell (jól) megválasztanunk, hogy a reciprok gyökkel rendelkezzen. Legyen

$$f(x) = \frac{1}{x} - w$$

Az fenti egyenlet gyöke, $f(x)=0$ esetén az $x = 1/w$. Ha $f(x)=1/x-w$, akkor

$$f'(x) = -\frac{1}{x^2}$$

Ekkor visszahelyettesítve az eredeti Newton-Raphson iterációs képletbe a következőt kapjuk:

$$x_{i+1} = x_i - \frac{\frac{1}{x_i} - w}{-\frac{1}{x_i^2}} = x_i + (x_i - wx_i^2) = 2x_i - wx_i^2 = x_i(2 - wx_i)$$


Tehát az A/B műveletet $A \cdot (1/B)$ alakra írtuk át, és az $1/B$ reciprokképzést egy szorzóval és egy kivonóval valósíthatjuk meg. A függvény Taylor sorának kiterjesztésével (négyzetes konvergencia) belátható, hogy minden egyes iterációs lépésben a helyes bitek száma megduplázódik. Tehát megfelelő iterációs lépés kiválasztásával a kívánt pontosság elérhető!

b.) Közvetlen gyors osztó


- Az iteratív osztási művelet másik módszere a következő: $Q = D_D / D_S$ kiszámolható a következő egyenlettel, ha a successive (egymást követő) f_k –k úgy vannak megválasztva, hogy a nevező az 1-hez konvergáljon.

$$Q = \frac{D_D \times f_0 \times f_1 \times f_2 \dots}{D_S \times f_0 \times f_1 \times f_2 \dots}$$

Közvetlen gyors osztó működése

- A számláló iterációja ennél a módszernél $D_{Dn+1} = D_{Dn} \times f_n$. A nevező iterációját a megismert módon használjuk a következő f -ek meghatározására.
- Tegyük fel, hogy szorzóink, 2'komplementes képző egységeink vannak, valamint a kezdő értéket tartalmazó ROM, vagy regiszter.
- Ezzel az iteratív osztási módszerrel az eredményt *közvetlenül* megkapjuk. Feltételezzük, hogy a számok itt normalizált lebegőpontos számok, az osztót és osztandót egy törtkifejezésként írjuk fel (mantissza egy normalizált tört).
- Keressük a Q hányados (quotient) értékét. Hogy megkapjuk, mind az osztó, mind pedig az osztandó értékét ugyanazokkal az f_k értékekkel kell megszorozni, amelyet úgy határozunk meg, hogy a nevező egységnyi legyen az iterációk elvégzése után. Így később a számláló értékéből megkapjuk a Q pontos értékét. Tudjuk, hogy D_S normalizált tört, ezért így ábrázoljuk: $D_S = 1-x$, ahol x -et D_S határozza meg, és mivel D_S kisebb 1-nél, így az x is kisebb 1-nél.

Közvetlen gyors osztó áramkörü felépítése



Közvetlen gyors osztó

- Az osztás művelete f_0 kiszámolásával kezdődik. Válasszuk $f_0 = 1+x = 1+(1-D_S) = 2-D_S$. Így $D_S \times f_0 = (1-x)(1+x) = 1-x^2$. Így sokkal közelebb kerültünk 1-hez, mintha csak a D_S -et használtuk volna. Minden iterációs lépésben a számláló és a nevező is f_k tényezőkkel szorozódik, és közelebb kerülünk a Q pontos értékéhez. Legyen $f_1 = 1+x^2$. Így $D_S \times f_0 \times f_1 = 1-x^4$ és ez tovább ismétелhető iteratív módon
- Tehát azt kapjuk, hogy $D_{Dn+1} = D_{Dn} \times f_n$.
- Egy kérdés vetődik fel: hogyan válasszuk meg f_k következő értékét. $f_1 = 1+x^2 = 1+(1-D_S \times f_0) = 2-D_S \times f_0$. Tehát minden egyes új f_k -t úgy kapunk meg, hogy vesszük az f_{k-1} és a D_S (nevező) szorzatának 2's komplementjét. Az iterációs lépéseket a kívánt pontosság eléréséig kell ismételni, amelyet f_k értéke határoz meg. Amikor f_k közelítőleg 1, akkor a Q eredmény elegendően közel lesz a kívánt eredményhez (amely az alkalmazástól és a bitek számától függ). Általában előre definiált fix számú iterációs lépést végzünk el. Ezért kell ROM-ot használni, amelyben az f_0 megfelelő kezdeti értékét tároljuk.
- (Példák: könyvben)

Példa 1.

Legyen az osztandó $D_D = 0.4$, osztó $D_S = 0.7$, és 6 iterációs lépésig számoljunk (7 tizedesjegy pontosságú számokkal). Ekkor $f_0 = 2 - D_S = 2 - 0.7 = 1.3000000$. Kérdés $Q = D_D / D_S$? $D_{Dn+1} = D_{Dn} \times f_n$.

- 0. $D_{D0} = 0.4000000$ $D_{S0} = 0.7000000$ $f_0 = 1.3000000$
- 1. $D_{D1} = 0.5200000$ $D_{S1} = 0.9099999$ $f_1 = 1.0900000$
- 2. $D_{D2} = 0.5668000$ $D_{S2} = 0.9918999$ $f_2 = 1.0081000$
- 3. $D_{D3} = 0.5713911$ $D_{S3} = 0.9999344$ $f_3 = 1.0000656$
- 4. $D_{D4} = 0.5714286$ $D_{S4} = 0.9999999$ $f_4 = 1.0000000$
- 5. $D_{D5} = 0.5714286$ $D_{S5} = 1.0000000$ $f_5 = 1.0000000$
- 6. $D_{D6} = 0.5714286$ $D_{S6} = 1.0000000$

Látható, hogy már a 4. iterációs lépésben megkaptuk a helyes eredményt ($D_{D4} = 0.5714286$), mivel D_S elég közel volt az 1-hez, és $x = 0.3$ volt. ($x = 1 - D_S$).

Példa 2.

Legyen az osztandó $D_D = 0.1$, osztó $D_S = 0.15$, és 6 iterációs lépésig számoljunk (7 tizedesjegy pontosságú számokkal). Ekkor $f_0 = 2 - D_S = 2 - 0.15 \approx 1,8499999$. Kérdés $Q = D_D / D_S$? $/D_{Dn+1} = D_{Dn} \times f_n./$

- 0. $D_{D0} = 0,1000000$ $D_{S0} = 0,1500000$ $f_0 = 1,8499999$
- 1. $D_{D1} = 0,1850000$ $D_{S1} = 0,2775000$ $f_1 = 1,7224999$
- 2. $D_{D2} = 0,3186625$ $D_{S2} = 0,4779938$ $f_2 = 1,5220062$
- 3. $D_{D3} = 0,4850063$ $D_{S3} = 0,7275094$ $f_3 = 1,2724905$
- 4. $D_{D4} = 0,6171659$ $D_{S4} = 0,9257489$ $f_4 = 1,0742511$
- 5. $D_{D5} = 0,6629912$ $D_{S5} = 0,9944868$ $f_5 = 1,0055132$
- 6. $D_{D6} = 0,6666464$ $D_{S6} = 0,9999696$

Látható, hogy itt nem kapjuk meg a kívánt értéket ($D_{D6} = 0,6666464$) 6 iterációs lépés alatt. Ezért hogy elérjük a kívánt pontosságot véges számú lépés alatt, ROM-ot kell használni (ahol f_0 kezdeti értékét tároljuk).

Extra bitek kezelése

- Truncation (levágás)
- Rounding (normál kerekítés)
- Zero-bias rounding (zéróhoz kerekítés R^*)
- Jamming
- ROM rounding

Extra bit: probléma

- Két 6-bites lebegőpontos szám összeadása, exponens egyeztetés után:

Nagyobb mantissza 101010

Kisebb mantissza + 110010 →

11011010 2

Extra bits

a.) Truncation (levágás)

- Levágás: egyszerűen elhagyjuk az extra biteket.
 - Hibája a pontosság: a kapott M_F mantissza eltér a valós mantissza M_R értékétől:

$$ERR_{TRUNC} = M_R - M_F$$

- n-bites bias (offset) hibája: tárolt érték mindig kisebb lesz, mint a valós/aktuális érték (mindig pozitív bias-t kapunk)
- Kevesebb extra bittel kisebb lesz a bias, így a hiba is csökken.

Truncation: példa

- ERR → bias: mindig pozitív

cases	MR	MF	ERR _{TRUNC}
a	xx0.00	xx0.	0.00
b	xx0.01	xx0.	+0.01
c	xx0.10	xx0.	+0.10
d	xx0.11	xx0.	+0.11
e	xx1.00	xx1.	0.00
f	xx1.01	xx1.	+0.01
g	xx1.10	xx1.	+0.10
h	xx1.11	xx1.	+0.11

b.) Rounding (kerekítés)

- Bias csökkentése a cél, úgy hogy a levágás előtt az LSB bit értékének a felét hozzáadjuk a számhoz:

Nagyobb mantissza

Kisebb mantissza

$$\begin{array}{r} 101010 \\ + \quad 110010 \\ \hline 11011010 \\ + 00000010 \\ \hline 11011100 \end{array}$$

→ 2 bitpoz.
8 bites eredmény
LSB poz. fele
Végeredmény (majd truncate)
Extra bits

PI: Rounding (kerekítés)

- ERR → bias: hiba itt is ugyan megmarad, de már pozitív és negatív is lehet (bias-a kisebb, mint a levágás esetén)

case	MR	MR+1/2 LSB	MF	ERR _{ROUND}
a	xx0.00	xx0.10	xx0.	0.00
b	xx0.01	xx0.11	xx0.	+0.01
c	xx0.10	xx1.00	xx1.	-0.10
d	xx0.11	xx0.11	xx1.	-0.01
e	xx1.00	xx1.10	xx1.	0.00
f	xx1.01	xx1.11	xx1.	+0.01
g	xx1.10	xy0.00	xy0.	-0.10
h	xx1.11	xy0.01	xy0.	-0.01

Változás a
truncate-hez
képest!

xy: g.)/h.) eseteknél „carry propagate” van, xx helyében („xx incremented to xy”)

c.) Round-to-Zero (R^* rounding)

- Cél. A hiba minimalizálása, lehetőleg zérus bias elérése, kerekítéssel.
- ERR_{ZERO} –kat összeadva a teljes bias értéke nulla lesz.
- Kisebb a hibája mint más extra-bit kezelő technikáknak

PI: Round-to-Zero (R^*)

case	MR	MR+1/2 LSB	MF	ERR _{ZERO}
a	xx0.00	xx0.10	xx0.	0.00
b	xx0.01	xx0.11	xx0.	+0.01
c	xx0.10	xx1...	xx1.	-0.10
d	xx0.11	xx1.01	xx1.	-0.01
e	xx1.00	xx1.10	xx1.	0.00
f	xx1.01	xx1.11	xx1.	+0.01
g	xx1.10	xy1...	xy1.	+0.10
h	xx1.11	xx1.11	xy0.	-0.01

← Változás a rounding-hoz képest!

Normál kerekítéshez képest a **c.)**/**g.)** eseteknél egy '1'-es lett direkt beállítva (force) az LSB helyén (xx1). De csak a **g.)** esetnél lesz más a hiba értéke (ERR_{ZERO}).

d.) Jamming (~fix értéken rögzítés)

- Neumann
- Csökkenteni a teljes hibát (jobb módszer, mint a truncation).
- Pl. *Jam to '1'*: LSB bitet fix-en '1'-re rögzítjük, az extra bitek értékétől függetlenül!
- Ennek a módszernek ugyan nagyobb a hibája, mint a legtöbb extra bit kezelő módszerek, de idővel ugyanolyan kicsi lesz a bias-a, mint a kerekítésnek.
- Olyan gyors viszont mint a truncation (itt nincs időszükséglet, mint a kerekítési fázisban, LSB-t mindig pl. '1'-re), ráadásul kis bias.

e.) ROM rounding

- Vizsgálat: extra biteket és LSB-biteket változatlanul hagyjuk
- Döntési folyamathoz ROM-ból való értékek kiolvasását használjuk
- Biztosítja, hogy a nagyobb bitpozíciókba nem kell „carry-t propagáltatni” (mint rounding-nál), gyorsabb is
- Bias kontrollálható (akár zérus is lehet végül)

Extra-bit kezelő módszerek összehasonlítása:

