

# Linux Assembly

Juhász Péter Károly "Stone"  
<stone@elte.hu>

2003. december 21.

## 1. Bevezető

A következőkben bemutatom, hogyan lehet, *GNU/Linux* alatt az *Assembly* nyelvet használni. Ehez a *NASM* 0.98.34-es verziója és a *GNU ld* 2.13.90.0.2-es verziója lesz segítségemre, az előbbi letölthető a <http://nasm.sourceforge.net> címről az utóbbi minden tisztességes Linux disztribúcióban megtalálható.

Az asszemly rejtelseibe a *Helló világ!* különféle változatain keresztül fogunk egyre beljebb ásni. A leg alapabtól egészen az olyanokig, amit *makrókat* és *eljárásokat*, fognak használni.

## 2. Helló világ! első változat

Egyenlőre semmi extra nincsen benne csak kiírja az üzenetet a képernyőre és kilép.

```
segment .text

        global _start

_start:
    mov     eax,4
    mov     ebx,1
    mov     ecx,msg
    mov     edx,len
    int     0x80

    mov     eax,1
    mov     ebx,0
    int     0x80

msg     db     "Hello vilag!",0x0a
len     equ     $ - msg
```

A program a következő parancskombinációval fordítható le:

```
nasm -f aout hello.asm
ld -s -o hello hello.o
```

Most nézzük meg egy kicsit közelebbről a programot! A program egy szegmensdefiniációval indul, ezt *.text*-nek nevezzük el. Minden programba kell legalább egy ilyen nevű szegmens. Ebbe kell egy *\_start:* címke amit a *global \_start* sorral tehetünk láthatóvá a linker számára erre is szükségünk van minden programba, hogy a linker aztán tudja, hogy hol van a futtatandó program eleje. Majd a program szövege.

Most nézzük a tényleges programot! Két részből áll a kiírásból és a kilépésből. Lássuk először a kiírást:

```

mov    eax,4
mov    ebx,1
mov    ecx,msg
mov    edx,len
int    0x80

```

Itt a Linux *write* rendszerhívását használjuk aminek ugyanazok a paraméterei mint a megegyező nevű C függvénynek: a file leíró, az üzenet címe és az üzenet hossza. Ezeket sorban az *ebx*, *ecx* és *edx* regiszterbe várja a program, az *eax*-be a *write* rendszerhívás száma kerül, ami 4. És mindezt a 0x80-as interrupt meghívásával hajthatjuk végre.

Jelen esetünkben a file leíró a sztenderd kimenet, aminek a kódja 1, az üzenet címére az *msg*: címke mutat az üzenet hosszát meg a *len*: címke által mutatott memóriaterületre számolja ki a fordító az üzenet eleji és az üzenet végi memóriacímek különbségéből, az *equ* direktíva segítségével.

Most nézzük a kilépést:

```

mov    eax,1
mov    ebx,0
int    0x80

```

A kilépést a *quit* rendszerhívás segítségével oldjuk meg, aminek a száma 1, amit megint az *eax*-be teszünk be. Az *ebx*-be megy az egyetlen paraméter a visszatérési érték, amit sikeres program végrehajtás esetén nullára szokás állítani. Az egészet megint a 0x80-as interrupt meghívásával hajthatjuk végre.

Most tergyünk egy kis kitérőt, a rendszerhívások irányába! Mik is azok és hogy kell őket használni? Mint *DOS*-ban már láttuk, van egy *int 21h* nevű valami, amit ha meghívunk akkor a regiszterek értékétől függően különféle dolgok történnek. Na a Linux *int 0x80* rendszerhívása nagyon hasonló ehez. A rendszerhívások listáját megtalálhatjuk a következő címen:

<http://www.lxhp.in-berlin.de/lhpsysc0a.html>

Valamint ha tudjuk a rendszerhívás számát, csak a paraméterekre nem emlékszünk hirtelen használhatjuk a *man 2* valami parancsot is mivel ugyanazok lesznek a paraméterek. Hála az isteneknek a Linux betartja a szabványokat.

### 3. Helló világ! második változat

Most módosítsuk egy kicsit az előző programot úgy, hogy a szöveget ne a képernyőre, hanem egy fileba írja ki. Ezzel megismerhetünk még két rendszerhívást valamint egy kicsit beljebb ásunk a szegmensek témakörébe.

```

section .data

msg    db    "Hello vilag!",0x0a
len    equ    $ - msg
file   db    "hello.txt",0
fd     dw    0

section .text
global _start

_start:
mov    eax,5
mov    ebx,file
mov    ecx,(1q|100q)
mov    edx,400q

```

```

int     0x80
mov     [fd],eax

mov     eax,4
mov     ebx,[fd]
mov     ecx,msg
mov     edx,len
int     0x80

mov     eax,6
mov     ebx,[fd]
int     0x80

mov     eax,1
mov     ebx,0
int     0x80

```

Nézzük meg közelebbről az újításokat! Feltűnt egy új dolog a `.data` szegmens. Ez egy írható és olvasható terület a programban, mivel a `.text` szegmens nem írható, csak olvasható. Itt azért van szükségünk arra, hogy az adataink írható területen legyenek, mert majd az `open` rendszerhívás által visszaadott file leírót elfogjuk tárolni, a későbbi felhasználás végett. Ezen felül még lehet, egy `.bss` nevű szegmens, amit a gép a még nem inicializált változóknak tart fent. Erre nem lesz szükségünk a továbbiakban.

A NASM nem foglalkozik a szegmens regiszterekkel, nincs *ASSUME* mint például MASM használatakor. Olyan értékeket állítunk be a szegmens regiszterekbe amit akarunk. Valamint a fordító nem generál *szegmens override prefixet* sem.

Most lássuk a program többi részét! Először is a file megnyitást:

```

mov     eax,5
mov     ebx,file
mov     ecx,(1q|100q)
mov     edx,4001
int     0x80
mov     [fd],eax

```

Az `open` rendszerhívás kódja 5, ez megy az `eax` regiszterbe, az `ebx`-be megy a file név, az `ecx`-be a flagek, itt konkrétan a `1q` (ez egy oktális szám, ezt jelzi a `q` e végén) ami a csak írásra való megnyitást jelenti valamint a `100q` ami a létrehozást jelenti, végezetül az `edx`-be jönnek a jogok, itt `400q` ami a tulajdonos által olvashatóságot jelenti. A többi bit flag értéket, valamint a jogokat mindenki megnézheti a fentebb említett weboldalon. A `0x80` az interrupt meghívása után az `open` a file leíró az `eax` regiszterben adja vissza, amit mi elmentünk az `fd` által hivatkozott és a `data` szegmensben létrehozott két bytenyi memóriaterületre.

A kiírásról annyit, hogy csak abban módusul, hogy az `ebx` regiszterbe nem 1-et, hanem az `fd`-ben tárolt fileleíró tetszük.

Végezetül jöjjön a file lezárása, amit a `close` rendszerhívással végzünk:

```

mov     eax,6
mov     ebx,[fd]
int     0x80

```

A hívás kódja 6, az egyetlen paramétere a file leíró, amit értelemszerűen az `ebx`-be vár.

Ezekután megint a már megtanult `quit` rendszerhívás maradt már csak hátra. Ami most változatlan, az előző változathoz képest.

## 4. Helló világ! harmadik változat

Most térjünk vissza az első helló világ programhoz és megint csináljunk rajta egykét módosítást, nevesen a *makrók* használatával!

```
%macro exit 1
    mov    eax,1
    mov    ebx,%1
    int    0x80
%endmacro

%macro print 1+
    jmp    %%end

%%msg    db    %1
%%len    equ   $ - %%msg

%%end    mov    eax,4
         mov    ebx,1
         mov    ecx,%%msg
         mov    edx,%%len
         int    0x80
%endmacro

section .text
    global _start

_start:
    print "Hello vilag!",0x0a
    exit 0
```

Nézzük meg egy kicsit közelebbről! Először is teszünk egy kis kitérőt a makrók irányába, mik is ezek? A makró az egy programrész, aminek van neve, és maraméterei, elég egyszer megírni és a programban később a nevével hivatkozhatunk rá. Hogyan kell makrókat megadni? Minden makrót a következő módon kell definiálni:

```
%macro makro_nev parameterek_szama
...
%endmacro
```

Ha paraméterszámnak olyat adunk meg, hogy például *2+*, akkor azt úgy veszi, hogy két paraméter lesz, de ha többet is megadunk akkor az utolsó paraméterhez csapja hozzá a felesleget. A mi programunkban a `print`-et `1+`-al definiáltuk így azt mondtuk meg neki, hogy bármennyi paramétert is adunk meg azok mind közösen az első paramétert alkotják. A paraméterekre a `%1`, `%2`, ...-al hivatkozhatunk. Használhatunk lokális címkéket is a makróban amiket a `%`-al kell kezdeni, pl.: `%%msg`. A paramétereket vesszővel elválasztva adjhatjuk át a makróra való hivatkozásokor.

Most lássuk a makróinkat! Itt van mindjárt az első:

```
%macro exit 1
    mov    eax,1
    mov    ebx,%1
    int    0x80
%endmacro
```

Itt egy `exit` nevű makrót definiálunk, aminek egy paramétere van, nevesen a kilépési státusz.  
Most nézzük az érdekesebb `print` makrót!

```
%macro print 1+
    jmp    %%end

%%msg    db    %1
%%len    equ   $ - %%msg

%%end    mov    eax,4
         mov    ebx,1
         mov    ecx,%%msg
         mov    edx,%%len
         int   0x80
%endmacro
```

Ennek is egy paramétere van, de ez már tartalmazhat vesszőket, ezért használtuk a `1+` paraméterszámot. A makró első utasításával elugrunk egy lokális címke által mutatott utasításra, erre azért van szükség, mert tettünk a makróba adatokat is amiket nem szeretnénk végrehajtani, ez `%%end` címke után meg már a megismert kiírás művelet található.

Most a programunk már csak két sor, ami erre a két makróra hivatkozik.

```
    print    "Hello vilag!",0x0a
    exit     0
```

Látható, hogy miért használtuk a `1+` paraméterszámot a `print` makrónál, így át tudjuk neki adni a sorvége `0x0a`-val ellátott sztringet paraméterként.

## 5. Helló világ! negyedik változat

Most nézzük meg, hogyan tudunk eljárásokat használni assembly nyelven. Itt is van a következő program ami pont ezt mutatja be.

```
section .text

    global _start

print:
    mov    eax, 4
    mov    ebx, 1
    mov    edx, [esp + 4]
    mov    ecx, [esp + 8]
    int   0x80
    ret

_start:
    mov    eax, msg
    push  eax
    mov    eax, len
    push  eax
    call  print
    add   esp, 8

    mov    eax, 1
    mov    ebx, 0
```

```

        int      0x80

msg     db      "Hello vilag!", 0x0a
len     equ     $ - msg

```

Nézzük, meg egy kicsit közelebbbről! A programban definiálunk egy `print` nevű eljárást, amit úgy írtunk meg, hogy két paramétere van az első a kiírandó szöveg címe, a második a kiírandó szöveg hossza. Ezeket, a vermen keresztül adjuk át neki, ezt írj le a következő négy sor:

```

        mov     eax, msg
        push   eax
        mov     eax, len
        push   eax

```

majd, a `call print` hívással adjuk át neki a vezérlést.

Maga a `print` eljárásunk a már megismert `write` rendszerhívás segítségével írja ki a szöveget. Ehhez a veremből kell kinyernie a két paramétert.

A verem tetejére a `call` hívás ráteszi a visszatéresi címet, így a paraméterek az alatt lesznek, aminek a címei sorban az `[esp + 4]`, `[esp + 8]`, `[esp + 12]`, ... lesznek.

Majd mint minden eljárásból ebből is valahogy visszakell térni a főprogramhoz, ezt a `ret` utasítással tehetjük (és teszszük is) meg.

Az eljárás után van egy olyan sor, hogy `add esp, 8` ez azért kell, mert a veremben még mindig benne vannak a függvényünk paraméterei és ezeket kikell szedni, és mivel a verem teteje fele vannak a kisebb címek és ha hozzádaunk 8-at azzal a legutolsó két `push` eredményét töröljük le.

A program többi részében nincsen semmi új, azok ugyanazok mint eddig.

## 6. Helló világ! ötödik változat

Most nézzük meg, hogy hogyan használhatjuk fel az assembly tudásunkat, ha például C-ben programozunk. A programunk még mindig a Helló világ legyen, de most írjuk meg C-ben de használjunk hozzá egy kis assemblyt!

A következő file-t nevezzük `main.c`-nek:

```

#include <stdio.h>

extern int osszead(int,int);

int main() {
    printf("Hello vilag! %d\n", osszead(2,3));
    return 0;
}

```

és ezt meg `osszead.asm`-nek:

```

bits    32

section .text

global  osszead

osszead:
        push   ebp
        push   esi
push edi
push ebx

```

```

    mov    eax,[esp + 20]
    mov    ebx,[esp + 24]
    add    eax,ebx

pop ebx
pop esi
pop edi
pop ebx

    ret

```

és fordítsuk le őket a következő módon:

```

nasm -f elf osszead.asm
gcc main.c osszead.o

```

és ha ezekután kipróbáljuk a következő kimenetet kapjuk:

```

Hello vilag! 5

```

Lássuk egy kicsit közelebbről, a C programban van egy külső függvény hívás amit az ismert `extern` kulcsszóval adtunk meg. Az assembly programunkban meg van egy ugyanolyan nevű publikus függvény (függvény, mert `ret` van a végén) ami összeadja a két paraméterként kapott számot.

Hogyan is működik ez? Először is az elején van egy olyan, hogy `bits 32` ez azért kell, hogy minden utasítást 32 bitesen fordítson, ez ahhoz kell, hogy a C programunkal kompatibilis legyen. Az assemblyben megírt függvény a C programtól a paramétereit, fordított sorrendben a veremben kapja meg. A verem tetejére még egy visszatérési érték is bekerül, így, a paraméterek címei sorban az `[esp + 4]`, `[esp + 8]`, `[esp + 12]`, ... lesznek, jelen esetben csak kettő. Mivel a programban még egykét regiszter értékét elmentjük a verembe ezek az értékek változnak jelen esetben 16-al nőnek. Ha ezeket nem mentenénk el akkor minélgy fordítóval Segmentation fault-os programot gyártanánk. Pontosan úgy, ahogy az előző programnál láttuk. A program beolvassa őket az `eax` és `ebx` regiszterbe, majd összeadja őket az `eax`-be. A függvények visszatérési értékét az `eax` regiszterbe kell tenni. Végül a `ret` utasítással visszatér a főprogramhoz.