

# Huhypn – magyar elválasztásiminta-gyűjtemény

Nagy Bence

2006. augusztus 7.

## Kivonat

A Huhypn elválasztásiminta-gyűjtemény létrehozásának célja az élő magyar nyelv szavainak hibátlan elválasztása szabad szoftveres környezetben. A mintagyűjtemény a TeX-ben és valamennyi a LibHnj programkönyvtárat használó alkalmazásban – a legjelentősebbek az OpenOffice.org és a Scribus – teszi lehetővé az algoritmus által megszabott keretek közötti magyar nyelvű elválasztást.

## 1. Áttekintés

### 1.1. Miért kell elválasztani?

A klasszikus könyvművészeti szövegeket minden témában szedéstelek helyezte el. A nyelv szavai egy általános szövegen azonban sohasem követik egymást olyan sorrendben, hogy egymás mellé helyezve egyenlő hosszúságú sorokat alkossanak. A betűk szerkezeti felépítése, a betűk egymásközti távolsága és a szavak közti távolság nemcsak esztétikai kérdés, hanem az olvashatóság szempontjából is fontos.

Amikor JOHANNES GUTENBERG a híres negyvenkét soros Bibliát készítette, egységesen keskeny szóközöket alkalmazott. A sorkizárást különböző szélességű betűk metszésével, ligatúrák és abbreviatúrák alkalmazásával érte le. Noha a latin nyelv betűi és írásjelei mintegy 60 jelet tesznek ki, Gutenberg 290 különböző jelet metszett. A mai napig esztétikai mintaképül szolgál.

Követője, PETER SCHÖFFER vezette be a manapság is leggyakrabban használt előjárás, a szóközök méretének változtatását. A szöveg szóközeinek növelése vagy csökkenése révén lehet elérni az egyforma hosszúságú sorokat. Esztétikai és olvasáspszichológiai okokból azonban nem szabad eltérni nagymértékben az alapszóköz méretétől. Ez abban az esetben valósítható meg jól, ha egy sorban minél több szóköz van, így az egyes sorhosszkülönbségeket szétosztva, azok kisebb mértékben növelik vagy csökkentik a szóközök méretét. Nemkívánatos az a jelenség, amikor az egyes szóközök mérete olyan nagymértékben nő, hogy azok akár a sorok közti távolságot is meghaladják.

Mivel a magyar nyelv agglutináló, vagyis a szótőhöz hozzáilleszti a toldalékokat, a szövegen a hosszú szavak igen gyakoriak, így az elválasztások alkalmazása nélkülözhetetlen, ha igényes szedés kialakítása a célunk. Ennek jelentősége nyomtatott dokumentumok esetén van, az interneten legelterjedtebb HTML-formátumú weboldalak nem tartalmaznak elválasztást, és alapesetben nem sorkizárt szövegeket jelenítenek meg.

## 1.2. Az elválasztás jelentősége

Amíg a  $\text{\TeX}$ -rendszer főleg tudományos körökben használt eszköz maradt fejlesztésének évei alatt, a Liang-féle elválasztó algoritmus problémái csak kevés embert érintettek. Mivel a  $\text{\TeX}$  nyílt rendszer, ezért bárki készíthet hozzá kiegészítéseket, javításokat, így korábban a szakértő felhasználók is orvosolni tudták gondjaikat, és elmondhatjuk, hogy a  $\text{\TeX}$  szellemiségebe beleillik ez a fajta felhasználói változtatás.

Az OpenOffice.org általános célú irodai programcsomag, amelybe szintén ezt az elválasztó algoritmust építették be, azonban ez a rendszer már a szélesebb közönséget célozza meg. A program a „középiskolás fokon” oktatott számítástechnikai ismeretekkel is egyszerűen használható, ezért elterjedése nem lehet kétséges. Mivel szabadon terjeszthető, ezért a Linux operációs rendszer elsőszámú irodai programcsomagjává vált, és része a legtöbb disztribúciónak – aki egy modern Linux disztribúciót telepít, az előbb-utóbb találkozik a programmal. Az asztali gépen Linuxot használók száma még csekély a Microsoft Windows felhasználóihoz képest, de valószínűleg ez utóbbi platformon is gyorsan fog nőni a programot használók száma, nem beszélve a többi operációs rendszerről, amelyen elérhető.

Az OpenOffice.org-ba épített LibHnj programkönyvtárat RAPH LEVIEN írta 1998-ban, ennek a magas szintű elválasztás és sorkiegyenlítés a feladata. Forráskódja szintén szabadon felhasználható, ezért várható, hogy újabb programokba is be fogják építeni.

Az egyik ilyen ismert alkalmazás, a Scribus tördelőprogram, melynek 2003. júliusában jelent meg az 1.0-s verziója, és jelenleg úttörőnek mondható a Linuxos DTP területén. Felhasználóinak száma minden bizonnal alacsonyabb az OpenOffice.org-énál, viszont ezen a területen nagyobb a jó elválasztás jelentősége.

Magyar nyelvű szövegek szedésének egyik sarkalatos pontja a helyes elválasztás. A helytelen elválasztás helyesírási hiba, az elválasztások kihagyása azonban a sorkizárt szövegben okozhatja a fent említett szóközönömlést. Nyelvünknek speciális elválasztási kívánalmai is vannak. A nyelvben több egyszerűsítve kettőzött hosszú mássalhangzó van, melyeket nem egyszerűen csak kettévalasztunk, hanem bizonyos betűk a két elválasztott részben megismétlődnek. Hogy érthetőbbé tegyem: az *asszony* szó az *asz-* és a *szony* tagokra választandó szét, erre azonban a  $\text{\TeX}$  beépített algoritmusára nem alkalmas. Mivel az ilyen betűk előtt is és után is egy-egy magánhangzó van, ha nem tudjuk elválasztani a szót, úgy egy legkevesebböt betűből álló láncot kapunk, mely gondot okozhat az egyenletes szóközök terén, ha a szó pont a sor végére esik.

A  $\text{\TeX}$  egész bekezdést vizsgáló sortörő algoritmusára annyira kifinomult, hogy optimális használatához a forrást a lehető legjobban kell előkészíteni.

## 1.3. A magyar nyelv elválasztási szabályai

A magyar nyelvnek egyszerűek az elválasztási szabályai: a szavakat szótágokra kell bontani, és az a szótághatárok mentén elválasztható. A szótárolt elválasztás nem alkalmazható összetett szavak esetén maradéktalanul, itt a szóösszetétel határára kell esnie az elválasztásnak. A szabály idegen szavak esetében a kiejtés szerinti szótárolást részesíti előnyben, ezért sok idegen szó számít csak egy szótárosnak és nem elválaszthatónak, még ha az eredeti alakban vagy annak átvett változatában több magánhangzó is szerepel.

A fenti két szabály ütközik, és ennek következtében a magyar elválasztási szabályok nem adnak egyértelmű utasítást arra az esetre, ha idegen eredetű szavak szerepelnek a szóösszetételekben. Ilyenkor A *magyar helyesírás szabályai*-ban leírtak szerint a meghatározatlan „átlagos magyar nyelvérzéknek” kell döntenie, hogy elfogadja-e vala-

mely összetevőt a magyarban is élő alaknak vagy pedig a szóösszetételelől függetlenül szótárolás szerint kell elválasztani.

A szótárolás szerinti történő elválasztás módszerét a szabályzat 226. paragrafusa tartalmazza. Rövid algoritmusa a következő: minden magánhangzó új szótágot jelöl, és a magánhangzók előtt szereplő másalhangzók közül minden az utolsót kell átvinni a következő sorba, és itt a tényleges másalhangzót kell érteni, többjegyű esetén valamennyi betűjének az új sorba kell átkerülnie.

Erre az algoritmusra könnyű programot írni, ez azonban csak a magyar nyelvre lesz használható, a HiOn is eszerint működik és a *T<sub>E</sub>X* magyar elválasztási mintáinak 3.12-es verziójáig az ezt megvalósító mintahalmazzal rendelkezett. Az összetett szavak elválasztásának problémáját mindenkor a szó kivétszótárba, illetve a minták közé történő közvetlen felvételével oldotta meg. Ennek hátránya nyilvánvaló: a szóösszetételek száma hatalmas, és ebben az esetben a hibásan elválasztott összetett szavakkal folyamatosan kell bővíteni a szótárat.

#### 1.4. A *T<sub>E</sub>X* módszere

A *T<sub>E</sub>X*-rendszerbe FRANK M. LIANG elválasztási algoritmusát építették be, amely előre megadott minták alapján határozza meg az elválasztási helyeket, és így bizonyos megszorításokkal valamennyi latin betűs nyelvre alkalmazható.

Liang 1980 és 1982 között dolgozta ki, és *Word hy-phen-a-tion by computer* című doktori értekezésében 1983-ban publikálta a számítógéppel történő elválasztás egy módszerét, amelyet a *T<sub>E</sub>X*-rendszerbe is beépítettek. A Liang-algoritmus gyorsan működik, és valamennyi olyan elválasztási helyet bejelöl, amelyet az elválasztási mintái között eltárolunk. Az algoritmust megvalósító kód igen egyszerű és kevés memóriát igényel, ez az állítás pedig tizenöt évvel kitalálása után hatványozottan igaz.

A *T<sub>E</sub>X* a következőképpen választ el. Ha megkap egy szót, először megnézni a kivétszótárat, hogy nincs-e definiálva benne ennek a szónak a különleges elválasztása. Amennyiben nem szerepel benne, úgy a Liang-algoritmussal választja el.

Az angol *hyphenation* szó elválasztásán keresztül mutatom be az algoritmus működését, Knuth maga is ezt a példát hozza fel, és FRICZ CREMER, a *The T<sub>E</sub>Xbook* németre fordítója, is ragaszkodott ehhez.

Az algoritmus a szót először kiegészíti két ponttal: *.hyphenation.*, majd pedig felbontja egyre növekvő hosszúságú szakaszokra. A pontok a szó elejét és végét jelentik, ennek fontos szerepe van, nemelyik elválasztási minta konkrétan csak szó eleji vagy végi helyzetben ad helyes elválasztást.

Az így kapott egybetűs szakaszok:

. h y p h e n a t i o n .

a kétféle betűsek:

.h hy yp ph he en na at ti io on n.

hárombetűsek:

.hy hyp ype pen ena nat ati tio ion on.

és így tovább.

Az így létrejött k hosszúságú szakaszokhoz k+1 számot társít, melyek az egyes betűk előtt fogják jelölni az elválasztási helyeket. A hen szakaszhoz négy szám kerül majd, melyet a következőképpen lehet szemléltetni:

0h0e2n0

A 2-es számjegy az e betű utáni lehetséges elválasztás információját tartalmazza.

Az elválasztás folyamata a továbbiakban úgy zajlik, hogy a program az előre eltárolt elválasztási mintákból megkeresi azokat, amelyek megegyeznek a szó szétbontott szakaszaival. A `hyphenation` szóra az angol nyelvi szótárból a következőket találja meg:

```
0h0y3p0h0  
0h0e2n0  
0h0e0n0a4  
0h0e0n5a0t0  
1n0a0  
0n2a0t0  
1t0i0i0  
2i0o0  
0o2n0
```

Az elválasztás utolsó lépése az, hogy az egyes betűk közé jutó értékek közül mindenig a legnagyobbat választja ki, majd a szavunkba illeszti azokat. A szó végül így fog kinézni:

0h0y3p0h0e2n5a4t2i0o2n0

Ahol a szóban páratlan szám található, ott elválasztható a szó, ahol páros vagy nulla, ott nem engedélyezett az elválasztás. A `hyphenation` szó tehát elválasztva: `hy-phen-ation`.

Ha összehasonlítjuk Liang doktori értekezésének címét és a végeredményt, lehet látni, hogy ez utóbbiban eggyel kevesebb elválasztási hely lett bejelölve, maga Knuth azt írja, hogy az elválasztási algoritmus az elválasztási helyek döntő többségét megtalálja. Megfelelően kialakított mintafájl esetén azonban valamennyi elválasztási helyet megkapjuk.

#### 1.4.1. A módszer hiányosságai

Az algoritmus egyik nagy hiányossága, mely mincket különösképpen érint, hogy nem képes az egyszerűsítve kettőzött hosszú mássalhangzókat elválasztani.

A `TEX` elválasztórendszerének másik hiányossága, hogy nem választja el azokat a szavakat, amelyekben kötőjel van. A 6–3-as szabály miatt a hosszú szóösszetételeket kötőjellel kell írni, de földrajzi nevekben is sokszor fordul elő ez az írásmód.

Erre a problémára megoldást jelent BERND RAICHLE `hypht1.tex` nevű fájlya, azonban ehhez mélyebben nyíl bele a `TEX` elválasztórendszerébe. A `\hyphenation` makróval lehet elválasztásokat megadni, amelynek kötőjellel elválasztott szavakat kell megadni. Kötőjeles alak esetén a kötőjel előtt egy egyenlőségejelet kell írni: `\hyphenation{Er-zsé-bet=-híd}`.

A `LATEX` Babel csomagjához készült stílusfájlból sikeresült megoldani az egyszerűsítve kettőzött hosszú mássalhangzók elválasztásának problémáját, azonban az csak jelentős többletmunka árán kelthető életre. A trükk lényege, hogy ezeket a karakterszorozatokat külön meg kell jelölni egy fordított aposztróffal: pl. `loccsan`, `fröccsen`.

## 2. A szótárfejlesztés

### 2.1. A régebbi modulok által felvetett kérdések

A Huhyph 3.12 és Huhyph 4.0 esetén alkalmazott módszerek akármelyikét vizsgálva jelentős nehézséggel kerülünk szembe.

A kézzel szerkesztett fonetikai bázisra épülő változatnál rengeteg szót kell megvizsgálni és a rájuk alkalmazható mintákat megtalálni. Az új minták felvétele esetén meg kell vizsgálni a régebbieket, hogy azok módosításával elérhető-e a kívánt eredmény, vagy az új minta felvétele esetén találkozunk-e olyan szóval, amelyiket eddig helyesen választott el, de az új minta felvételével már hibásan.

A Huhyph 4.0 módszerével készített kollekció esetén pedig akkor érhetünk el optimális eredményt, ha egy szóhoz valamennyi képzett alakjának elkészítjük az elválasztott formáját, és felvesszük a szótárba. A Huhyph 4.0 szókészlete nem haladja meg a 70000-es méretet, a mintagenerálás folyamata azonban a dokumentációja szerint egy 1 GHz-es Pentium IV-es számítógépen majdnem nyolc percet vesz igénybe. Amennyiben minden szónak további változatait képezzük, úgy a művelethez szükséges idő nagyságrendekkel nőhet, és akár óráig is tarthat. Nem lehetünk azonban biztosak ekkor sem abban, hogy a szótárból hiányzó szavak megfelelően választódnak el, csak reménykedhetünk, hogy a szótár növekedésével a fonetikai szabályok és a növekvő számú azonos kivételek átlépik azt a kritikus tömeget, hogy érvényesüljenek a nem felvett szavakra is.

### 2.2. A PatGen

A PatGen kiválóan használható alkalmazás, hogyha meg tudjuk kerülni a használatából származó hátrányait. A fenti problémák alapján két elvárásnak kell megfelelni:

- A generált minták tartalmazzák teljes egészében a fonetikai szabályokat, hogy a szótárban nem szereplő szótagok esetén is érvényesüljenek.
- A generált minták ne befolyásolják a fonetikai szabályok szerint választandó szavak elválasztását.

Az első elvárást egyszerű teljesíteni, a PatGen-t előre elkészített mintákkal kell megíjni, amelyek tartalmazzák a szótagolás szerinti elválasztás szabályait.

A második elvárás teljesítése a nehezebb, ugyanis itt a PatGen működése okozza a problémát. A program ugyanis a bemeneti szótárt alapul véve határozza meg az összetétel szerint elválasztandó szavak esetében a szükséges alkalmazandó mintát. Mivel optimális megoldásra törekzik, ezért ez a minta a lehető legrövidebb lesz, és így könnyen előfordulhat az, hogy egy szótárban nem szereplő, a fonetikai szabályokkal elválasztató szónál hibás elválasztást fogunk kapni.

A PatGen megfelelő paraméterezésével érhetjük el, hogy ne törekedjen optimális eredmény generálására, de ebben az esetben is a bemeneti szótár duzzasztására van szükség. Nem agglutináló nyelvek esetén bőven elég lenne a szó felvétele a szótárba, de a magyarban minél több toldalékoltságot fel kell venni. Erre egy módszer, ha könyvek szavait a Hunspell-en keresztül átszűrjük. Ez a helyesírás-ellenőrző meg tudja mondani egy szóról, hogy az valamely szótőnek a toldalékoltsági alakja-e. Ha ismerjük a szótő elválasztását, akkor a toldalékoltsági alak elválasztását is meghatározhatjuk, mivel a toldalékok minden esetben a fonetikai szabályok szerint választandók el. A szótár növekedése ebben az esetben nem lesz annyira drasztikus, minta egy algoritmussal valamennyi létező

toldalékolt alakot felvennénk, ugyanis így csak a ténylegesen használt formák kerülnek a szótárba.

A PatGen alkalmazásával elkerülhető, hogy a TeX kivételezőt kelljen használni az ismeretlen vagy hibás elválasztású szavak esetén, elég a szót felvenni a program bemeneti szótárába, és az új mintafájl már megfelelően fogja kezelní ezt a szót is.

A szótár gyarapodásával együtt jár a feldolgozási idő növekedése, de ezt az árat meg kell fizetnünk.

### 2.3. A Szószabolya

A Szószabolya projekt (<http://www.szoszabolya.hu/>) a magyar web feldolgozásával olyan szóanyagot állított össze, amely a ma beszélt magyar nyelv szókészletét nagy mértékben lefedi. A teljes szóanyagból a nagy gyakorisággal előfordulókat ki-válogatva és a Hunspell helyesírás-ellenőrzőn átszűrve olyan szótárat kapunk, amely ideális lehet az elválasztási mintagyűjtemény bemeneteként.

## 3. Fejlesztőkörnyezet

### 3.1. Források

#### 3.1.1. Patgen

A minták generálását a teTeX disztribúció patgen alkalmazása végzi. A `magyar.tra`, a `patgen.in` és a `base.pat` fájlok a program működéséhez szükséges paramétereiket tartalmazzák. A `patgen.patch` alkalmazása a nagy mennyiségű adat feldolgozásához szükséges, jelenleg nem ismert, hogy ilyen paraméterek mellett mekkora bemeneti szótár feldolgozására képes, a mintegy 2700000 szavas állomány esetén sikkerrel használható.

#### 3.1.2. Substrings.pl

Az OpenOffice.org a módosított algoritmusú LibHnj-t használja, ehhez a csomagban lévő `substrings.pl` használatával a kész minták átalakítására van szükség.

#### 3.1.3. A szótár

A bemeneti szótár mintegy 45 MB méretű, a szótár magját képező szógyűjteményt a `web2.2-mostfrequent-hungarian-words.txt.gz` fájl tartalmazza, ezt a Szószabolya projekt weboldaláról lehet letölteni. A majdnem teljes bemeneti szótár előállításához a `test.rb` program módosításával juthatunk, ha azt csővezetékbe kötve futtatjuk a fenti fájlon.

### 3.2. Működés

A folyamat a `Makefile`-on keresztül a `make` parancs kiadásával történik. A `patgen` formátumfüggetlen mintagyűjteményt hoz létre, melynek felhasználásával az `eruby` program (ezt külön kell telepíteni) a `.tmpl` végű sablonfájlok ból elkészíti a mintagyűjtemény különböző változatait.

## 4. Telepítés

### 4.1. Telepítés TeX alá

A TeX-rendszerhez rendelkezésre álló mintagyűjtemény a `.tex` nevű fájlban található. A fájlban található karakterek az EC-, T1- vagy más néven Cork-kódolás szerint szerepelnek. Ez a szokásos magyar nyelvű L<sup>A</sup>T<sub>E</sub>X használat mellett eredményezi a megfelelő működést. A fájt a `texmf-fa /tex/generic/hyphen` könyvtárába kell másolni, majd a `mktexlsr` programmal frissíteni a fájlnyilvántartást.

A fájl megfelelő helyre másolása és a konfigurációs fájlok szükséges módosítása után szükség van a formátumfájlok legenerálására, mivel a szótárak feldolgozása nem futásidőben történik. A teTeX-rendszeren a beállítások végrehajthatóak a `texconfig` programmal, amely a különböző makrócsomagoknál teszi lehetővé az eltérő beállítás használatát, és gondoskodik a formátumfájlok elkészítéséről is. Az alábbiakban a kézzel történő beállítások találhatóak.

#### 4.1.1. L<sup>A</sup>T<sub>E</sub>X

A L<sup>A</sup>T<sub>E</sub>X makrócsomag esetén a betöltendő elválasztási minták a `language.dat` fájlban találhatóak. Ennek szokásos helye a `texmf-fa`

```
/tex/generic/config
```

könyvtár. Szerepelnie kell benne egy

```
magyar huhypth.tex
```

tartalmú sornak, esetleg százalékkel az elején. Ezt a sort tegyük megjegyzésbe, és egy másik sorba írjuk a következőt:

```
magyar huhypnh.tex
```

A formátumfájl legenerálásakor már a `Huhypnh` elválasztási mintái épülnek be.

### 4.2. Telepítés OpenOffice.org alá

Az `OpenOffice.org` irodai programcsomaghoz használható elválasztási mintafájl a `hyph_hu.dic` nevet viseli. Ezt a következő könyvtárba másolva írjuk felül az eredeti változatot (a könyvtár disztribúciótól függően változhat):

```
/usr/lib/OpenOffice.org/share/dict/ooo/
```

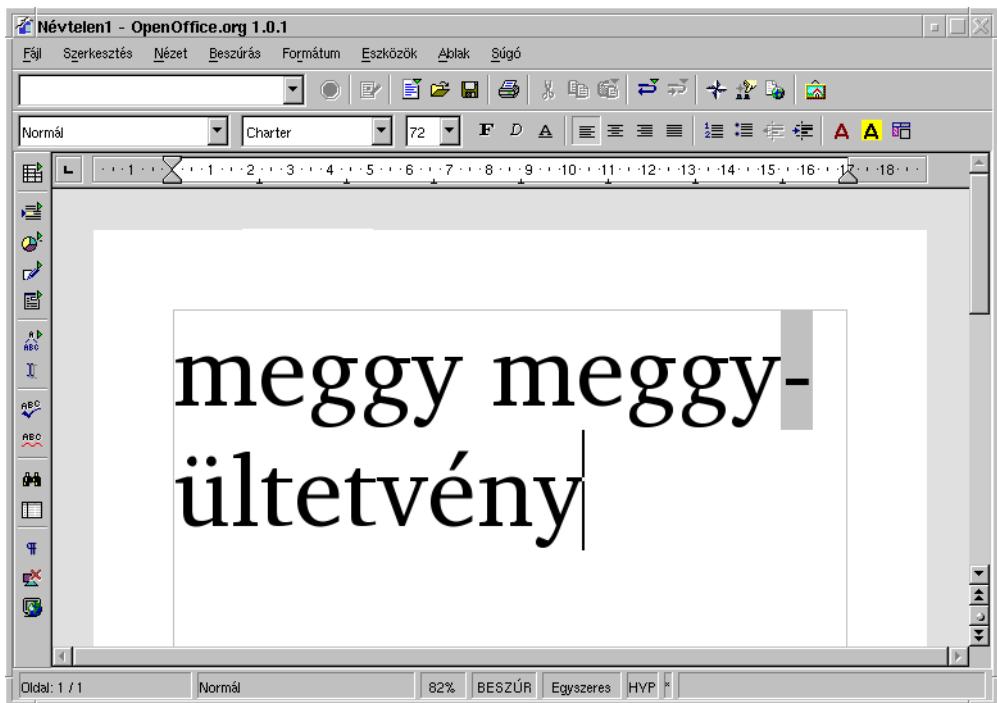
A program ezek után már a `Huhypnh` elválasztási mintáit használja.

### 4.3. Telepítés Scribus alá

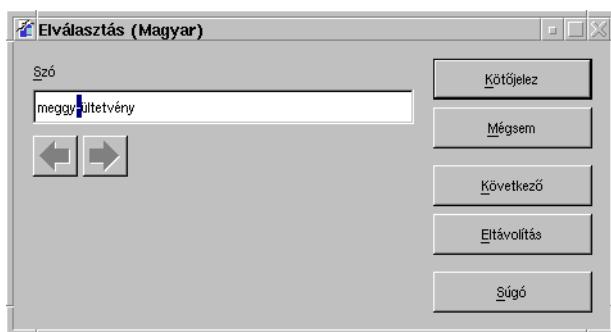
A `Scribus` az elválasztási mintákat a

```
/usr/lib/scribus/dicts/
```

könyvtárban tárolja, ide kell másolni a `hyph_hu.dic` fájlt (az 1.1-es verzió nem engedi szimlink használatát).



1. ábra. Az *OpenOffice.org* ablakában immár a helyes elválasztás.



2. ábra. Az elválasztás engedélyezésének ablaka.

## **5. Elérhetőség**

A <http://www.tipogral.hu/> oldalon érhetőek el a projekt keretében létrehozott elválasztómodulok és programok, melyeket a GPL-licenc feltételei szerint lehet felhasználni.