

Huhypn – magyar elválasztás TEX-hez, Scribus-hoz és *OpenOffice.org*-hoz

Nagy Bence

2003. október 11.

Kivonat

A Huhypn projekt célja olyan elválasztómodul kidolgozása, amely hibátlanul választja el az élő magyar nyelv szavait. Ez az elválasztómodul a TEX és valamennyi a *LibHnj* programkönyvtárat használó alkalmazás (például az *OpenOffice.org* és a *Scribus*) számára teszi lehetővé az algoritmus által szabott keretek között magyar nyelvű szövegek elválasztását.

1. A régi Huhyp

A TEX-ben és az *OpenOffice.org*-ban eddig használt elválasztómodult – *Huhyp 3.12* – tekinthettük a hivatalos magyar elválasztómodulnak. Ezt a modult MIKLÓS DEZSŐ hozta létre 1989-ben, majd MAYER GYULA fejlesztette tovább, és jelenleg is ő a Huhyp-vonal karbantartója. A legújabb változat – *Huhyp 4.0* – kísérleti jellegű, és noha 2002 júniusában megjelent már, nem került be a disztribúciókba. A *Huhyp 3.12* és a *Huhyp 4.0* verziók között lényeges szemléletbeli különbség van.

1.1. Huhyp 3.12

A magyar nyelv elválasztásában a fonetikus és az összetétel szerinti szabályok játszanak szerepet. Általánosságban elmondhatjuk, hogy minden szót a fonetikai szabályok szerint kell elválasztani, azonban összetett szavak esetében az elválasztási pontnak az összetétel határára kell esnie. Idegen eredetű szóösszetételeknél e két szabály alkalmazása ingadozhat.

A *Huhyp 3.12* ezért azt az elvet követi, hogy az elválasztási minták alapját a kézzel rögzített fonetikai szabályok adják, és majdnem minden egyes összetétel elválasztását külön minta szabályozza. Így minden egyes szó elválasztása a fonetikai szabályok szerint történik, hacsak nem került be a kézzel szerkesztett minták közé az ezt szabályzó kivétel.¹ A módszer hátránya nyilvánvaló, hiszen minden egyes összetett szót, amelynél a fonetikai szabályok szerinti elválasztás nem az összetétel határára esik, külön fel kell venni a minták közé.

Olvasáspszichológiaiag indokolható, hogy az összetételek határán lévő egy szótagot képző magánhangzók az elválasztás során az őket tartalmazó összetevőben maradjanak, ezért gyakran az amúgy jól elválasztódó szavakra is külön mintát kell alkalmazni. Nyelvtanilag lehetséges a rádió-óadó és a rádió-a-dó forma, de vitán felül áll a rádió-adó változat elsőbbisége.

A kézzel szerkesztett mintagyűjtemény esetén felmerülhet, hogy a kollekció kevésbé optimálisan tárolja az egyes kivételeket lekezelő mintákat. Bővítmény során erre tekintettel kell lenni, ezért egy-egy minta hozzáadása alapos utánagondolást és a többi minta átnézését igényli.

¹ VERHÁS PÉTER *HiOn* programja is ezt az elvet követi, kiegészítve az ikekötők kezelését megoldó véges állapotú automatával.

1.2. Huhyp 4.0

A *Huhyp 4.0* már a FRANK LIANG és PETER BREITENLOHNER által fejlesztett *PatGen* programmal készült. A *PatGen* egy elválasztásokat tartalmazó szótár alapján hozza létre az elválasztási minták kollekcióját, így a *Huhyp 4.0* változatának alapja is egy nagyméretű szótár, mely a a *TypoTEX* Kiadó néhány könyvének szóanyagát tartalmazza.

A *PatGen*-nel történő mintagenerálás nagy hiányossága, hogy a létrehozott modul teljes bizonyossággal csak a szótárban szereplő szavakon működik. A program optimális eredményt ad a megadott szótárra vonatkoztatva, de ez nem jelenti azt, hogy ez a nyelv szavaival egészre érvényes. Mivel a magyar nyelv agglutináló, ezért rengeteg toldalék, illetve toldalékok kombinációja járulhat egy-egy szóhoz. Nyelvünkben létezik a hangkivetős tövek jelensége is, amikor úgy tűnik, mintha az egyes toldalékok nem az alapszóhoz, hanem annak módosulatához csatlakoznának. Ezért sok esetben hibás elválasztást kapunk egy ragozott szónál akkor is, ha annak töve szerepel a szótárban.

1.3. A Huhyp 3.12 és a Huhyp 4.0 hiányosságai

A fentiek alapján látható, hogy a magyar nyelvű elválasztási minták generálása korántsem egyszerű feladat. A *Huhyp 3.12* és *Huhyp 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, amelyik eddig helyesen választódott el, de az új minta felvételével már hibásan.

A *Huhyp 4.0* módszerével készített kollekció esetén pedig akkor érhetsünk el optimális eredményt, ha egy szóhöz valamennyi képzett alakjának elkészítjük az elválasztott formáját, és felvesszük a szótárba. A *Huhyp 4.0* szókészlete nem haladja meg a 70.000-es méretet, a mintagenerálás folyamata azonban 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. A szótárfejlesztés alapelvei

A *PatGen* kiválóan használható alkalmazás, hogyha meg tudjuk kerülni a használatából származó hátrányait. A fenti problémák alapján két elvárasnak 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 meghívni, 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 törekszik, ezért ez a minta a lehető legrövidebb lesz, és így könnyen előfordulhat az, hogy egy szótárban nem szereplő, a fonetikai szabályokkal elválasztható 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 toldalékolat alakot fel kell venni. Erre egy módszer, ha könyvek szavait a *Mispell*-en keresztül átszűrjük. Ez a helyesírás-ellenőrző meg tudja mondani egy szóról, hogy az valamely szótőnek a toldalékolat alakja-e. Ha ismerjük a szótő elválasztását, akkor a toldalékolat 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 toldalékolat alakot fellevennék, ugyanis így csak a ténylegesen használt formák kerülnek a szótárba.

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

3. A magyar elválasztás jelentősége

Amíg a TeX-rendszer főleg tudományos körökben használt eszköz maradt fejlesztésének évei alatt, a Liang-féle elválasztó algoritmus problémái csak kevés embert érintettek. Mivel a TeX nyílt rendszer, ezért bárki készíthet hozzá kiegészítéseket, javításokat, így korábban a szakértő felhasználók is orvosolni tudták gondjaikat, és elmondhatjuk, hogy a 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 nóni 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. Felhasználónak minden bizonnal alacsonyabb az OpenOffice.org-énál, viszont ezen a területen nagyobb a jó elválasztás jelentősége.

4. Felhasznált projekteredmények

A *Huhypn* fejlesztése során több szabadon elérhető projekt eredményének felhasználása történt meg.

4.1. ElMe

Az *ElMe* az Egyszerű Linuxos Morfológiai Elemző rövidítése. A projektet NAGY VIKTOR indította 1999-ben, a programnak mindenkorban egy 0.1-es változata készült el. A program egyszerű morfológiai elemzőként szolgál, egy szóról leválasztva annak toldalékait meghatározza a szófaját.

A program része egy nagyméretű szógyűjtemény, mely a Szóvégmutató szótár adatbázisát használja, és mintegy 58.000 szót tartalmaz. Az adatbázis a szavakon kívül nyelvtani információkat is tartalmaz, melyek alapján meg lehet határozni azok szófaját és szóösszetételek esetén az összetevők számát.

Az összetevők számának ismeretében egy keresőprogrammal sikerült azokat összete-vőkre bontani, a szó különböző darabokra bontott részeit kerestük a szótár nem összetett szavai között, és ez csekély hibászálaték és jól meghatározható hibajelenségek mellett jó eredményt adott. Az összetevőket ezek után már a fonetikai szabályok szerint el lehetett vá-lasztani. Mivel az idegen eredetű összetételek más jelést kaptak, ezért azok feldolgozását elkülnöntve lehetett elvégezni, és a többi összetétel esetén biztonsággal lehetett használni a fonetikai szabályokat.

Mivel a szövegűjtemény a 70-es évekből származik, ezért sok helyen a nyelv változása miatt helyesírási hibát és néhol az ékezetes betűknél elgépelést tartalmaz. Ezért a szavak szűrésen és javításon is átmentek.

4.2. Magyar Ispell

A *Magyar Ispell* projektet NÉMETH LÁSZLÓ indította el. Célja, hogy szabad szoftverek felhasználásával magyar nyelvű helyesírás-ellenőrzőt készítsenek. A projekt eredményei már ma is lenyűgözők, noha még mindig nincsen belőle hivatalosan kiadott verzió.

Ezt a helyesírás-ellenőrzőt használja a magyar *OpenOffice.org*, és parancssorból használva *TEX*-források, *HTML*- és *XML*-dokumentumok is ellenőrizhetők vele.

A *Huhypn* projekt céljaként szerepel a *Magyar Ispell* által nyelvtanilag megfelelőnek ítélt szavak hibátlan elválasztása. A *Magyar Ispell* szóállománya folyamatosan bővül, felé-pítésének köszönhetően egyszerű hozzá szaknyelvi modulok létrehozása és karbantartása.

Mivel a célrendszer megegyeznek a *Huhypn* által kitűzöttékkel, ezért a *Magyar Ispell* szóállományának felhasználása folyamatosan meg fog történni.

A szótárba felvett toldaléktalakok képzését is a *Magyar Ispell* projekt keretében ké-zülő *Hunspell* alkalmazás egyszerűsíti meg.

4.3. HiOn

A *HiOn* elválasztóprogramot VERHÁS PÉTER írta. A program a fonetikai szabályokat fel-használva működik, és ezt kiegészítendő egy összetett szavakat tartalmazó kivéteszótárat tartalmaz. Ebben sok olyan szó megtalálható, amely máshol nem szerepel, ezért ezek fel-vétele is megtörtént.

4.4. Huhypn 4.0

A megfelelő magyar elválasztómodul létrehozására indított eddig legnagyobb projekt MAYER GYULA érdeme. Az általa létrehozott szótár minimális számú hibát és az általa alkalmazott elvektől való eltérést tartalmaz. A szótár sok olyan idegen eredetű nevet és szöösszetételt tartalmaz, melyek elválasztásához tudományos szintű nyelvészeti ismeretek szükségesek, ezeknél mindenkorban érdemes a szótár általi változathoz ragaszkodni.

5. Telepítés

A *Huhypn* elválasztási mintái találhatók meg az 1.0.2-es Linuxos és újabbról, az 1.0.3-as Windowsos és újabb verziójú magyar fordítású *OpenOffice.org*-ban, a 0.9.9-es verziójú és újabb *Scribus*-ban, valamint az UHU-Linux 1.1-es változatának *TeX*-csomagjában is.

Mivel eddig szokásom szerint gyakran kerültek ki a különböző javítások és bővítmények, ezért érdemes lehet áttekinteni az egyes rendszerekhez történő telepítés módjait.

5.1. Telepítés *TeX* alá

A *TeX*-rendszerhez rendelkezésre álló mintagyűjtemény a *huhypn.tex* nevű fájlban található. A fájlban található karakterek az EC-, T1- vagy más néven Cork-kódolás szerint

szerepelnek. Ez a szokásos magyar nyelvű L^AT_EX használat mellett eredményezi a megfelelő működést. A fájlt 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 teT_EX-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.

5.1.1. L^AT_EX

A L^AT_EX 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 százalékjellel az elején. Ezt a sort tegyük megjegyzésbe, és egy másik sorba írjuk a következőt:

```
magyar huhypnh.tex
```

A formátumfájl legenerálásakor már a Huhyphn elválasztási mintái épülnek be.

5.1.2. ConTeXt

A ConTeXt más megközelítést használ. A texmf-fában található a

```
/tex/context/config/cont-usr.tex
```

nevű fájl, melyben a rendszer minden egyes elválasztási mintához definiál egy egységes szinonimát. A magyar nyelv definícióját a következő sor tartalmazza.

```
\definefilesynonym [lang-hu.pat] [huhypth.tex]
```

Ez kell módosítani az alábbira:

```
\definefilesynonym [lang-hu.pat] [huhypnh.tex]
```

Ha még nem tettük volna meg, törljük a százalékjelet a következő sor elejéről, ezzel érhetjük el, hogy a magyar elválasztási minták beforduljanak a formátumba.

```
% \installlanguage [\s!hu] [\s!status=\v!start] % hungarian
```

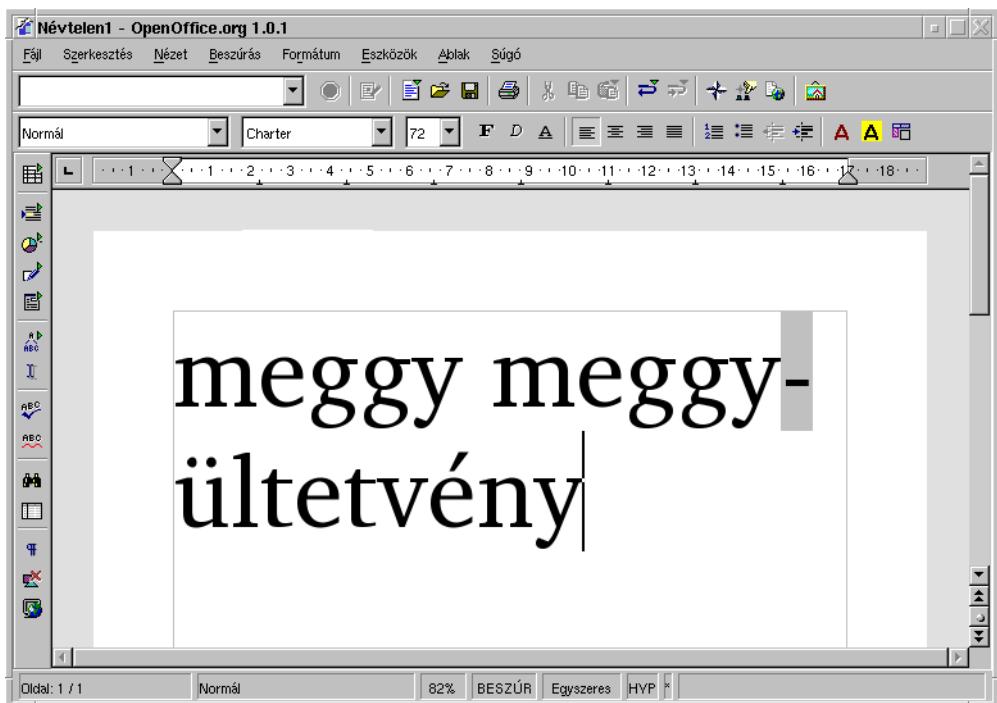
Ezek után generáljuk le a formátumfájlt.

5.2. Telepítés OpenOffice.org alá

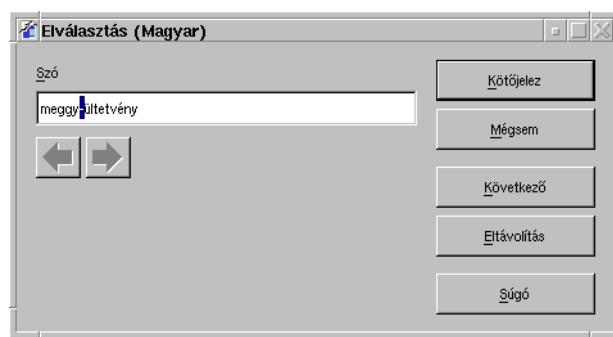
Az OpenOffice.org irodai programcsomaghoz használható elválasztási mintafájl a hyph_hu.dic nevet viseli. Ezt a következő könyvtárba másolva írjuk felül az eredeti változatot (a könyvtár disztribúciótól függően változhat):

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

A program ezek után már a Huhyphn elválasztási mintáit használja.



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



2. ábra. Az elválasztás engedélyezésének ablaka.

5.3. 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).

A *Scribus.hu* (<http://scribus.tipogral.hu>) magyar változat minden legfrissebb elválasztási mintákat tartalmazza.

6. Az elválasztómodul tesztelése²

6.1. Tesztelés

Az elválasztómodul tesztelésére külön alkalmazás szolgál. A *Testhyphenation* Ruby nyelven írt program, mindenben egy fájlból áll, mely a `testhyphenation.rb` nevet viseli. A Ruby programnyelvről bővebb információt a <http://www.ruby-lang.org/> oldalon lehet találni, innen tölthető le a rendszer forráskódja is.

A programot elindítva szavakat írhatunk be szöveges terminálon, melyeket kiír elválasztva, valamint az illeszkedő elválasztási mintákat is felsorolja. Így hibás elválasztás esetén egyszerű megállapítani, hogy azt mely helytelen minta okozhatta. Egy üres enter lenyomásával léphetünk ki a programból.

A program működéséhez a *TEX*-hez készült elválasztási mintafájlt (`uhuhyphn.tex`) használja. Mivel ebben a fájlban a hungarumlautos ékezetes betűk az EC-kódolás szerintiek, a mintákat beolvasáskor a Latin2-es kódkészletre konvertálja át.

6.2. Hibakeresés

A *Searchforerrors* alkalmazás a `searchforerrors.rb` fájl futtatásával indítható. A programnak bemenetként egy fájlnevet kell megadni, melyből a csak betűkből álló szavakat elválasztja, és ezekben hibák után kutat. Ez a program szintén a *TEX*-hez készült elválasztási mintafájlt használja fel.

Háromféle hibát lehet kiszűrni vele:

1. Csak egy mássalhangzó kerül két elválasztójel közé.³ Ezt a hibajelenséget egy túlságosan optimalizált minta okozza, mely a szó szótárba vételével egy hosszabb alakot fog felvenni.
2. Csak egy magánhangzó kerül két elválasztójel közé, melyek másik oldalán mássalhangzók állnak. Ez csak abban az esetben lehetséges, hogyha a magánhangzó szóösszetétel határán áll. Mivel összetett szavak határánál az egybetűs szótagok elválasztása nem ajánlott, ezért ezt is hibának tekintjük.
3. Az egyszerűsítve kettőzött hosszú mássalhangzók mellett mássalhangzó vagy eltérő hangrendű magánhangzók⁴ állnak. Ebben az esetben minden bizonnal összetett szóról van szó, így egy elválasztójel elhelyezésére mindenkorban szükség van.

²A példán látható „meggyültetvény” szót NÉMETH LÁSZLÓ küldte nekem, ezt egyik korábbi magyar modul se választotta el helyesen.

³Ilyen legfeljebb idegen szavak vagy régies nevek esetén és csak kétjegyű mássalhangzóknál fordulhat elő, de ez igen ritka.

⁴Az i és í magánhangzók hangrendje ingadozik, ezért ezeket nem vizsgálja, mert a legtöbb esetben csak téves risztást adna.

```
xterm
gimb:"/huhyphn" ./testhyphenation.rb
Testhyphenation v20030319
Minták betöltése...
9054 minta betöltve.

meggyültetvény
.m2
1me
g2y
1te
1vé
n2y
g2gy
1gyü
2ény
ggylül
meggyültetvény -> meggy-ül-tet-vény
```

3. ábra. A *Testhyphenation* futása szöveges terminálban, az alkalmazott minták egy tabulátorhellyel beljebb íródnak ki az elválasztott szó felett.

Eddigi tapasztalataim alapján úgy tűnik, hogy egy fájlban minden összes egy-két ezreléknél ilyen jellegű hiba fordul elő. A leggyakoribb hibafajta – egy összetett szó a fonetikus szabályok szerint formailag helyesen, de egyébként az összetételt tekintve hibásan van elválasztva – ezzel a programmal nem fedezhető fel, így az ilyen szavak megtalálása a továbbiakban sem nélkülözheti az emberi tényezőt.

7. Elérhetőség

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

```
xterm
gimb:"/huhyphn" ./searchforerrors.rb tipograf.txt
Searchforerrors v20030324
Minták betöltése...
10408 minta betöltve.
félé-v-ez-re-des
gimb:"/huhyphn"
```

4. ábra. A *Searchforerror* futása szöveges terminálban. SZÁNTÓ TIBOR A *tipográfia nyelve* című cikkét a MEK-ről töltöttem le, ebben a fájlban minden összes egy hibát talált.