

# Programinės įrangos vertimo specifika ir dalinis automatizavimas

Rimgaudas LAUCIUS (MII)

el. paštas: rimga@ktl.mii.lt

**Reziumė.** Straipsnyje nagrinėjama programinės įrangos vertimo specifika bei dalinio jos vertimo automatizavimo priemonių galimybės ir su tuo susijusios problemos. Remiantis statistine verčiamo teksto analize, išvertinamas dažnai pasikartojančių frazių vertimo priemonių taikymo naudingumas.

## 1. Ižanga

Lokalizuojant programinę įrangą išskiriami trys pagrindiniai darbai: 1) adaptavimas lokalei; 2) sasajos teksto (meniu, dialogų langų, pranešimų) vertimas; 3) žinynų vertimas.

Lokalė – tai „naudotojo aplinkos poaibio, priklausančio nuo kalbos ir kultūros normų, apibréžimas“ (ISO/IEC 15897). Lokalės normoms adaptuota PĮ suteikia galimybes rengti dokumentus, atitinkančius toje lokalėje galiojančias nuostatas bei teisinių vaizduoti išverstą sasajos tekštą [6].

Adaptavus PĮ lokalės normoms, atliekamas sasajos teksto ir žinynų vertimas. Nereiktai lokalizuojant PĮ apsiribojama jos adaptavimu lokalei ir sasajos tekštų vertimu, nes žinynų vertimas dėl jų didelės apimties gali būti sunkus ir nemažų investicijų reikalaujantis darbas. Tačiau žinynai taip pat yra svarbi PĮ dalis, todėl bendru atveju, tik atlikus visus tris minėtus darbus, galima laikyti PĮ pilnai lokalizuota.

Verčiant žinynus paprastai atliekamas ir sasajos teksto vertimo testavimas. Verčiant žinyną tenka nuodugniai nagrinėti programą ir paaiškėja didelė dalis programos veikimo ir taikymo aspektų, kurie galėjo likti nepastebeti verčiant sasajos tekštą, todėl netiksliai išverstas sasajos teksto frazes galima pataisyti. Kadangi PĮ sasajos teksto vertimo derinimo sąnaudos yra daug didesnės nei pats vertimas, todėl žinynų vertimas šiuo aspektu taip pat yra gana reikšmingas [5].

Sasajos ir žinynų teksto vertimas sudaro didžiąjį lokalizavimo darbų dalį ir reikalauja nemažų investicijų. Todėl, buvo nuspresta atlikti tyrimą, siekiant išsiaiškinti ar jo vertimui nebūtų galima panaudoti kokių nors vertimą automatizuojančių priemonių, kurios jį palengvintų.

## 2. Automatizuoto vertimo priemonės

Šiuolaikines automatizuoto vertimo priemones galima suskirstyti į dvi grupes:

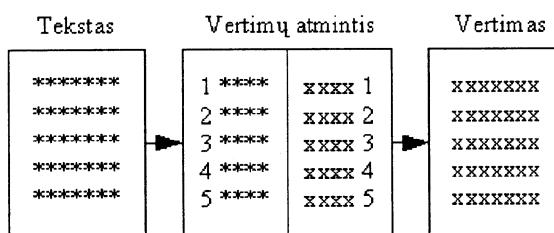
- naudojančios vertimų atmintį (*Translation Memory*);
- naudojančios gramatinę analizę.

Vertimų atmintį EAGLES (Expert Advisory Group on Language Engineering Standards) apibrežia kaip „daugiakalbio teksto archyvas, talpinantis segmentuotą, rikiuotą, išanalizuotą ir klasifikuotą daugiakalbių tekštą ir sudarantis galimybę laikyti ir išrinkti susietus daugiakalbio teksto segmentus pagal įvairius paieškos kriterijus“. Kitaip žodžiais kalbant, tai daugiakalbio teksto duomenų bazė. Šie duomenys yra gana universalūs įvairių vertimo sistemų atžvilgiu, todėl tam, kad jie nebūtų pririšti prie konkrečios programinės įrangos, sukurtas vertimų atminties laikymo ir keitimosi standartas TMX (Translation Memory eXchange). Šis OSCAR (Open Standards for Container/Content Allowing Re-use) atvirasis XML standartas suteikia galimybę keistis vertimų atmintimi tarp skirtinį vertimo programų ir vertėjų su minimaliais svarbios informacijos praradimais.

Vertimų atmintį naudojančių priemonių veikimo principas gana paprastas. Šios priemonės ieško vertimų atmintyje teksto vienetų (sakinį arba frazių), sutampačių su verčiamo teksto vienetais ir radus juos, automatiškai pakeičia jau anksčiau išverstu tekstu. Ši procesą iliustruoja paveikslėlis (1 pav.) pateikta schema. Plačiai žinomas šios grupės vertimo priemonės yra: Trados (<http://www.trados.com>), Déjà vu X (<http://www.atril.com>), SDLX (<http://www.sdl.com>), Star TermStar (terminology) and Transit XV (<http://www.star-group.net>), Word Fast (<http://www.champollion.net>), Terminology Wizard (<http://www.synthema.it>), Metatexis (<http://www.metatexis.com>).

Priemonės, naudojančios gramatinę analizę, veikia kitaip. Jos naudoja ne ankstesnių vertimų atmintį, o sudėtingą terminų duomenų bazę, į kurią ištraukti visi gramatiniai kalbos elementai. Šios priemonės versdamos ne tik naudoja išsamius žodynus, tačiau tuo pačiu taiko gramatinės taisyklės arba duomenų bazėje esančius taisyklių rinkinius tam, kad išversti sakiniai būtų gramatiškai taisyklingi. Šios grupės priemonės gali gana taisyklingai gramatiškai versti tekštą, tačiau jos neišsaugo ankstesnių vertimų. Todėl ateityje verčiant labai panašų tekštą (pvz., tos pačios programos kitos versijos žinyną) jis yra verčiamas nuo nulio.

Skirtingų kalbų gramatika gali būti labai skirtinė, todėl gramatinę analizę naudojančios priemonės nėra universalios skirtinį kalbų atžvilgiu. Kiekvienai skirtinbai kalbai yra naudojamas tik jai sukurtas sudėtingas gramatinis analizatorius. Šios grupės priemonių, pritaikytą lietuvių kalbai, kiek autorui žinoma, dar nėra sukurta. Plačiai žinomas šios grupės priemonės, skirtos užsienio kalboms yra: Promt Expert (<http://www.promt.ru>), Personal Translator (<http://www.lingenio.de>), Systran 5.0 (<http://www.systransoft.com>).



1 pav. Vertimo, panaudojant vertimų atmintį, procesas.

Siekdami išsiaiškinti automatinio vertimo priemonių taikymo ypatumus, pa-bandėme jas taikyti verčiant „OpenOffice.org“ programinę įrangą. Nors priemonės taikytos verčiant konkrečią programinę įrangą, tačiau gauti rezultatai yra bendro pobūdžio.

Visos automatizuoto vertimo priemonės yra gana brangios, todėl bandymui pasirinkome vertimų atmintį naudojančią priemonę Déjà vu X. Ji leidžia bandomojo mėnesio laikotarpiu naudotis visomis jos galimybėmis. Be to, ji geriausiai atitiko mūsų poreikius [1].

Bandymas parodė, jog priemonės, naudojančios vertimų atmintį, iš tiesų gali būti labai sėkmingesni taikomos verčiant programinę įrangą. Daugelis frazių nors ir verčiant skirtingą programinę įrangą kartojasi ir todėl, sukaupus nemažą vertimų atmintį, naujų programų arba tų pačių programų naujų versijų vertimą naudojant šias priemones galima atlirkti žymiai sparčiau. Tačiau, kol tokia atmintis nėra sukaupta, jų taikymas nėra efektyvus.

Verčiant didelės apimties tekstus, daugelis frazių pasikartoja po kelis ir daugiau kartų tame pačiame tekste. Todėl, vertimo apimtį galima sumažinti išverčiant vieną iš pasikartojančių frazių ir vėliau ja pakeičiant likusias. Mūsų taikyta priemonė Déjà vu X taip pat turi tokia galimybę. Ji išrenka ir parodo dažnai pasikartojančias frazes, tačiau ši jos galimybė mūsų pilnai nepatekino, nes išverstos frazės pakeitimais netgi gana sparčiai kompiuteryje (su 2,7 GHz procesoriumi) užtrukdavo santykinai ilgai. Todėl, šių frazių atrankai buvo nuspręsta paieškoti kitos efektyvesnės ir paprastesnės priemonės.

### **3. Dažnai pasikartojančiu teksto frazių paieška**

„OpenOffice.org“ olandų lokalizuotojų grupė yra pateikusi dažnai pasikartojančių frazių išskyrimui skirtą priemonę „FrequentStrings“ [2]. Tačiau paaškėjė, jog ji taip pat nėra tobula: veikia lėtai, naudoja daug operatyviosios atminties, nepateikia jokios informacijos apie verčiamą tekstą ir turi klaidų eliminuojant iš tolesnės paieškos pofrazius. Todėl, teko sukurti naują dažnų frazių išskyrimui skirtą programą. Jai buvo keliami tokie reikalavimai:

- Turi veikti sparčiai ir naudoti santykinai nedaug operatyviosios atminties.
  - „OpenOffice.org“ tekštą sudaro per 400 000 žodžių, o iš jų gaunama per 160 000 frazių, todėl siekiant sukurti sparčiai veikiančią ir santykinai nedaug atminties naudojančią programą, reikia taikyti efektyvius duomenų analizės algoritmus ir programavimo technologijas.
  - Turi būti išvengta pofrazių pasikartojimo.
- Dažnai pasikartojančios frazės nebenturi būti skaičiuojamos ieškant frazių sudarytų iš mažiau žodžių. Turi būti išvengta taip vadinamo „laiptų“ efekto, pavyzdžiu: „Frazė pasikartoja 100 kartų“, „pasikartoja 100 kartų“, „Frazė pasikartoja 100“.

Šias problemas pavyko sėkmingai išspręsti taikant maišos algoritmą ir dinaminio programavimo technologiją. Algoritmo esmę sudaro 3 dalyas:

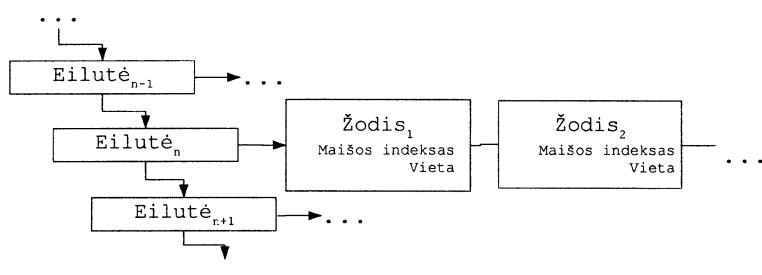
1. Teksto eilutės (po pirminio verčiamo teksto apdorojimo gaunama tekstinė byla sudaryta iš atskirų teksto vienetų – eilučių, tai gali būti ištisi sakiniai, tačiau gali būti ir sakinių frazės) išskaidomos žodžiais ir sukuriamas eilučių dinaminis

sarašas, sudarytas iš jas sudarančių žodžių ir jų maišos indeksų masyvų (2 pav.).

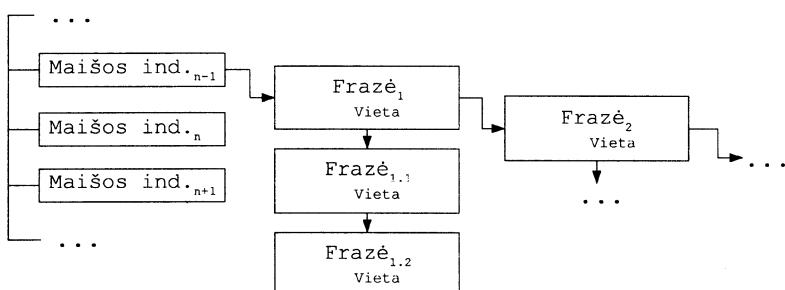
Tai atlikus, vėliau neberekia kiekvieną kartą skaičiuoti frazių maišos indeksų iš naujo, o pakanka sudėti frazes sudarančių žodžių maišos indeksus.

2. Iš eilutėse esančių žodžių sudaromos visos galimos frazės iš nustatyto skaičiaus žodžių. Taupant atmintį, frazė žymima nuoroda į eilutę bei pirmo ir paskutinio ją sudarančių žodžių indeksais toje eilutėje. Informacija apie frazė įrašoma į dinaminį sarašą, kuris įrašomas į masyvo elementą su frazės maišos indeksu (3 pav.). Taip surašius frazes, vėliau jas lengva surasti pagal jų maišos indeksą, todėl vienodū frazių paieška užtrunka labai trumpai.
3. Tiksina frazių masyvą ir išveda į bylą dažnai pasikartojančias frazės bei pašalinā jas iš frazių ir žodžių dinaminį sarašą tam, kad būtų išvengta jų pofrazių pasikartojimo.

Šis algoritmas kartojamas mažinant nustatytą žodžių frazės skaičių, nuo pasirinktinai ilgiausios frazės iki pasirinktinai trumpiausios frazės. Lyginant šią priemonę su „FrequentStrings“, akivaizdūs šie jos pranašumai: veikia ~45 kartus sparčiau, naudoja ~70 kartų mažiau operatyviosios atminties, gali pateikti detalią statistinę informaciją apie analizuojama tekstą.



2 pav. Eilučių dinaminis sarašas sudarytas iš žodžių dinaminiu masyvu.



3 pav. Dinaminiai frazių sarašai.

#### 4. Teksto analizės rezultatai

Siekiant nustatyti kokioms sąlygomis esant patenkintoms priemonę taikyti yra naudingiausia, išnagrinėjome „OpenOffice.org“ verčiamą teksto sandarą. „OpenOffice.org“ programos sąsajos tekstas savo sandara nuo žinynų teksto beveik nesiskiria. Žinynų tekstas pateikiamas XML formatu ir XML gairės daugumą sakinių suskaido į trumpas frazes, kurios yra būdingos ir sąsajos tekstui. Todėl jų vertimo specifika šiuo atveju artima sąsajos teksto vertimui ir todėl pateiksime tik žinynų teksto analizės rezultatus.

Analizuojant tekstą nustatyta, kad jį sudaro per 75 000 teksto eilučių, kurių vidutinis ilgis 5,4 žodžio (iš viso yra apie 404 350 žodžių, jie sudarytų per 600 mašinraščio puslapį). Ilgiausią eilutę sudaro net 145 žodžiai, tačiau didžiąją teksto dalį (virš 90%) sudaro eilutės trumpesnės nei iš 10 žodžių.

Taip pat buvo nagrinėta atskirų žodžių dažnumo ir jų padengiamo teksto procentais priklausomybė. Nustatyta, kad tekste yra ~2,7% teksto, kuris sudarytas iš nė karto nepasikartojančių žodžių, viso tekste yra 22 460 žodžiai, iš jų 11 083 nepasikartojačių (čia skaičiuojami visi žodžiai, kurie skiriiasi bent viena raide, neatsižvelgiant į jų reikšmę). Žodžių, kurie pasikartoja 10 ir daugiau kartų yra 3 524 ir jie padengia ~90% viso teksto; žodžių, kurie pasikartoja 20 ir daugiau kartų – 2 137 ir jie padengia ~85%. Net jei imtume žodžius, kurie pasikartoja 200 ir daugiau kartų, jų yra 273, jie padengtu ~60% teksto.

Dešimt dažniausiai pasikartojančių žodžių yra: *the* 34529 kartus, *to* (9253), *a* (9160), *of* (7919), *in* (7647), *and* (6360), *you* (5518), *is* (4872), *for* (3447), *or* (3410). Kaip ir buvo galima tikėtis, visi šie žodžiai pagalbiniai ir dauguma jų neturi atitikmenų lietuviškame tekste.

Pažvelgus į pateiktus rezultatus gali susidaryti išpūdis, kad pakanka išversti keletis tūkstančius žodžių (maždaug kaip šio straipsnio apimtis) ir likusius automatizuoti pakeitus, vertimas bus beveik atliktas. Tačiau iš tokio pakeitimo geriausiu atveju būtų naudos tik todėl, kad dalies žodžių nereikėtų surinkti nuo pradžios, o juos tik pataisyti, nes kardinaliai skiriiasi anglų ir lietuvių kalbų žodžių darybos ir sakinių sintaksės taisyklės. Be to, dauguma anglų žodžių, tame tarpe ir kompiuterinių terminų, yra daugiareikšmiai. Pavyzdžiui, *From...to = Kas...kam* (el. laiške), *Nuo ... iki* (kai kalbama apie intervalą); *check = pažymeti* (varnele), *tikrinti* (pvz., rašybą), *tab = tabuliacijos ženklas* (dokumente), *kortelė* (dialogo lange) ir t. t. [5].

Nevienareikšmiškumą padaugėja ir dėl to, kad daugelis tų pačių anglų žodžių (vienodai rašomų) gali atliki ir daiktavardžio ir veiksmažodžio funkcijas, pavyzdžiui, *file = byla, idéti, užpildyti; view = rodinys, rodyti; list = sarašas, išvardyti; bookmark = adresas, išrašyti adresą* ir t.t. [5].

Dėl šių priežasčių atskirų žodžių vertimas labai priklauso nuo sakinio ar frazės konteksto. Todėl verčiant po vieną žodį gero efekto nepasiekumėme. Gali būti netgi priešingai, tokiu būdu išverstą tekstą būtų žymiai sunkiau derinti ir todėl vertimui reikštų dar didesnių sąnaudų, nei verčiant paprastai. Realią naudą galėtume gauti tik versdamis dažnai pasikartojančias frazes, kuriose aiškus kontekstas ir todėl aiškios jų sudarančių žodžių reikšmės bei daryba.

Tačiau kaip nustatyti, kuriose frazėse aiškus kontekstas, o kuriose ne? Suprantama, kuo frazė ilgesnė, tuo didesnė tikimybė, kad jos kontekstas bus aiškus. Tačiau tiksliai nustatyti ilgio ribą nuo kurios frazės arba pakankama frazių dauguma turi kontekstą,

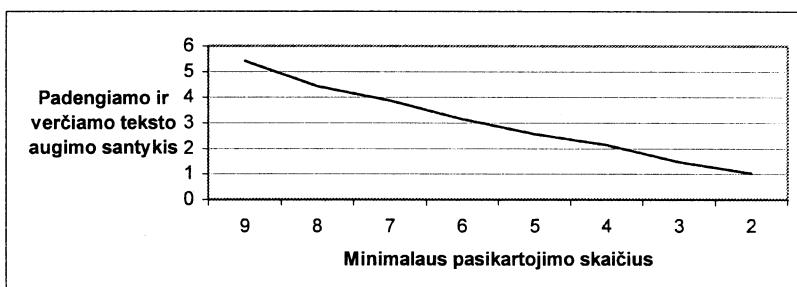
sudėtinga. Iš karto aišku, kad neverta nagrinėti frazių, sudarytų iš dviejų žodžių. Tai pažymi ir kiti tyrinėtojai [7], įvertinę automatinių priemonių taikymo efektyvumą nau-dodami BLEU metodą [8].

Kita aktuali problema, kurią čia nagrinėsime, – nustatyti minimalų frazių pasikarto-jimų skaičių, kada iš frazių vertimo automatizavimo būtu galima gauti daugiausia nau-dos. Akivaizdu, kad mažinant minimalų frazių pasikartojojimų skaičių yra padengiamas daugiau verčiamo teksto, tačiau dėl to nukenčia vertimo kokybė. Tyrimas parodė, kad maksimalus padengiamos teksto kiekis  $\sim 54\%$  pasiekiamas, kai imamos frazės, kurios pasikartoja po du ir daugiau kartų. Padengiamas tekstas sudaro  $\sim 33\%$ , kai verčiamos frazės pasikartoja 5 ir daugiau kartų ir  $\sim 25\%$ , kai 10 ir daugiau kartų.

Mažinant minimalų frazių pasikartojojimų skaičių (PS) padengiamama daugiau teksto, tačiau didėja ir iš šių frazių gaunamas verčiamas tekstas. Akivaizdu, kad santykis tarp padengiamos teksto (PT) ir verčiamos teksto (VT) (PT/VT) mažėja, o kartu mažėja ir galimo priemonės panaudojimo efektyvumas. Šis mažėjimas yra gana staigus bei artimas tiesinei priklausomybei (PT/VT =  $2 \times PS - 1,4$ ). Minimumas 2,6 pasiekiamas esant pasikartojojimų skaičiui 2 (teoriškai tai reiškia, kad panaudojant priemonę versti reiktų 2,6 kartus daugiau teksto, nei jo padengia frazės) pasiekiamas imant frazes, kurios pasikartoja du ir daugiau kartų.

Tyrimas parodė, kad priklausomybė nuo minimalaus pasikartojojimų skaičiaus išreiškiančios funkcijos neturi aiškių lokalių ekstremumų ar linkio taškų, kuriuos galima būtų tyrinėti ir taip nustatyti optimalų minimalaus frazių pasikartojojimų skaičių. Iš staigaus padengiamos ir verčiamos teksto santykio mažėjimo aišku, kad padengiamos teksto apimtis mažinant frazių pasikartojojimų skaičių auga žymiai lėčiau. Todėl, reikia įvertinti jų augimo santykį ( $PT_{PS+1} - PT_{PS}/VT_{PS+1} - VT_{PS}$ ). Šis santykis pateiktas tolesnėje diagramoje (4 pav.), iš jos matyti, kad esant pasikartojojimų skaičiui lygiam dvejetui, santykis artimas vienetui. Tai reiškia, kad nors sumažinę pasikartojojimų skaičių nuo trijų iki dviejų, gauname maksimalią padengiamos teksto apimtį, tačiau iš to beveik negauname naudos, nes verčiamos ir padengiamos teksto apimtys padidėja beveik po lygiai.

Iš diagramos matyti, kad mažinant minimalų frazių pasikartojojimų skaičių, mažėja priemonės panaudojimo efektyvumas. Be to, žvelgiant į diagramą, taip pat reikia turėti



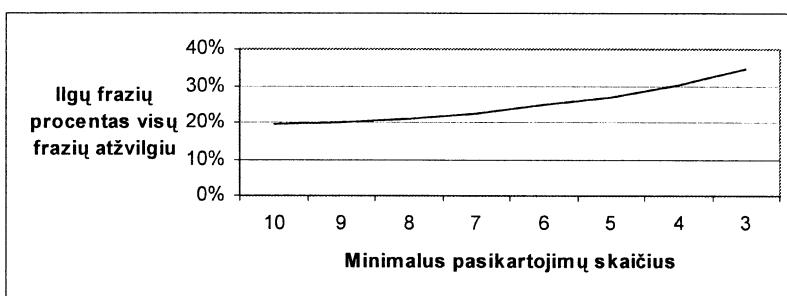
4 pav. Padengiamos ir verčiamos teksto augimo santykio priklausomybė nuo frazių pasikartojojimų skaičiaus.

omenyje, kad dalis frazių (typač trumpų) neturės aiškaus konteksto ir dėl to efektyvumas sumažės dar labiau. Todėl svarbus faktorius, įtakojantis vertimo efektyvumą, – ilgų frazių santykis visų frazių atžvilgiu. Atliekant tyrimą, ilgomis frazėmis laikysisime frazes sudarytas iš 5 ir daugiau žodžių. Jų santykio visų frazių atžvilgiu priklausomybė nuo frazių pasikartojimų skaičiaus pateikta diagramoje (5 pav.). Iš jos matyti, kad mažinant frazių pasikartojimų skaičių šis santykis didėja.

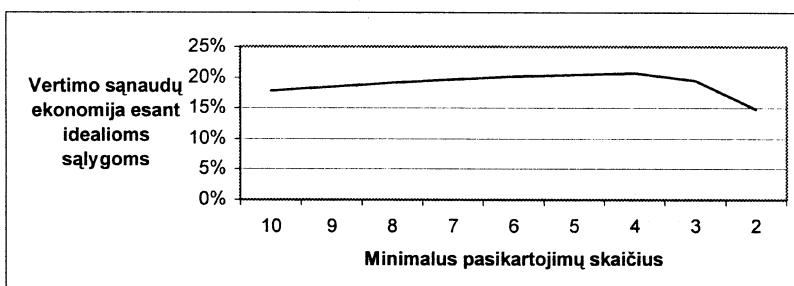
Mažinant minimalų frazių pasikartojimų skaičių didėja padengiamo teksto apimtis, tačiau mažėjantis padengiamo ir verčiamo teksto santykis bei mažėjantis jų augimo santykis rodo automatinio vertimo efektyvumo mažėjimą. Iš dalies ši efektyvumo mažėjimą atsveria didėjantis ilgų frazių santykis visų frazių atžvilgiu, tačiau šis didėjimas nėra didelis ir todėl nėra itin reikšmingas.

Įvertinant padengiamo teksto ir verčiamo teksto santykį viso teksto atžvilgiu esant idealioms sąlygoms, pasiekiamą vertimo sąnaudą ekonomija procentine išraiška, pateikta diagramoje (6 pav.).

Nors ši diagrama rodo, kad didžiausia ekonomija pasiekiamą esant pasikartojimų skaičiui lygiam 4, tačiau įvertinant visus nagrinėtus aspektus, rekomenduotinas optimalus frazių pasikartojimų skaičius būtų lygus 5 arba 6. Imant bet kuri iš šių skaičių, ekonomija sumažėtų labai mažai, tačiau priemonės taikymas būtų efektyvesnis dėl didesnio padengiamo ir verčiamo tekštų apimties santykio.



5 pav. Ilgų frazių santykio visų frazių atžvilgiu priklausomybė nuo frazių pasikartojimų skaičiaus.



6 pav. Ilgų frazių santykio visų frazių atžvilgiu priklausomybė nuo frazių pasikartojimų skaičiaus.

Diagramoje pateikta ekonomijos išraiška esant idealioms sąlygoms. Kaip iš jos matyti, esant tokiomis sąlygoms maksimaliai vertimo sąnaudas būtų galima sumažinti net penktadaliu. Tačiau dėl jau ankšciau išdėstyto priežasčių, realybėje sąlygos anaipol nėra idealios. Be šių priežasčių galima paminėti ir tai, kad panaudojus priemonę, pasunkės išverstų žinynų redagavimas. Todėl, įvertinus visas aplinkybes, ekonomija smarkiai sumažėtų. Pagal ankstesnę vertimą patirtį galima apytiksliai numatyti, kad geriausiu atveju taikant priemonę galima tikėtis per pus mažesnės ekonomijos, nei ji būtų pasiekiamą esant idealiomis sąlygomis.

## 5. Išvados

Vertimo priemonės gali būti labai sėkmingai taikomos verčiant programinę įrangą, kai yra sukaupta pakankama panašaus teksto vertimų atmintis.

Vertimą iš dalies galima automatizuoti verčiant tik po vieną iš dažnai pasikartojančių frazių ir vėliau ja pakeičiant likusias. Tokiu būdu galima pasiekti reikšmingą vertimui reikalingą sąnaudą ekonomiją. Pagrindinės priežastys, neleidžiančios pasiekti didelės ekonomijos, yra žodžių daugiareikšmišumas, žodžių darybos ir sakinių sintaksės taisyklių skirtumai.

## Literatūra

1. Atril. What's Déjà Vu.  
<http://www.atril.com/whatsdv.html> (žiūrėtas 2004-09).
2. S. Brouwer, Pre-translation of the OpenOffice.org help files.  
<http://nl.openoffice.org> (žiūrėtas 2003-12).
3. EAGLES (Evaluation of Natural Language Processing Systems). Benchmarking translation memories. Doc. EAG-EWG-PR.2  
<http://isscc-www.unige.ch/ewg95> (žiūrėtas 2004-09).
4. G. Dennett, *Translation Memory: Concepts, Products, Impact and Prospects*, South Bank University, London (1995).
5. G. Grigas, Interneto programų paketo lietuvinimo patirtis, *Informacinių technologijos: Konferencijos pranešimų medžiaga*, KTU, Kaunas (2003).
6. R. Laucius, V. Dagienė, Raštinės biuro programinės įrangos „OpenOffice.org“ adaptavimas lokalės normoms. *Konferencijos pranešimų medžiaga. Kompiuterininkų dienos – 2003*, Vilnius (2003).
7. P. Koehn, F.J. Och, D. Marcu, *Statistical Phrase-Based Translation*. [www.isi.edu/~marcu/papers/phrases-hlt2003.pdf](http://www.isi.edu/~marcu/papers/phrases-hlt2003.pdf) (žiūrėtas 2004-10).
8. K. Papineni, S. Roukos, T. Ward, W.-J. Zhu, BLEU: a method for automatic evaluation of machine translation. *Technical Report RC22176 (W0109-022), IBM Research Report* (2001).

## SUMMARY

### R. Laucius. Software translation specifics and partial automation

There is analysis of software translation specifics and possibilities of partial automatic translation, presented in this paper. Referencing on statistical text analysis the efficiency of automated translation tools application is estimated.

**Keywords:** automatic software translation, translation memory.