Usporedna analiza alata za strojno prevođenje

Popadić, Dragana

Master's thesis / Diplomski rad

2017

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, Faculty of Electrical Engineering, Computer Science and Information Technology Osijek / Sveučilište Josipa Jurja Strossmayera u Osijeku, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:200:022640

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-29**

Repository / Repozitorij:

Faculty of Electrical Engineering, Computer Science and Information Technology Osijek

zir.nsk.hr

Image not found or type unknown

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU
FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I INFORMACIJSKIH TEHNOLOGIJA

Sveučilišni studij

USPOREDNA ANALIZA ALATA ZA STROJNO PREVOĐENJE

Diplomski rad

Dragana Popadić

Osijek, 2017.

SADRŽAJ

1. UVOD 1
1. 1. Problematika istovrijednosti 1
1.2. Zadatak diplomskoga rada 2
1.3. Struktura diplomskoga rada 3
2. POVIJESNI RAZVOJ STROJNOGA PREVOĐENJA 4
3. VAŽNOST AUTOMATIZACIJE PREVOĐENJA 7
4. SVRHA STROJNOGA PREVOĐENJA 9
5. KARAKTERISTIKE STROJNOGA PREVOĐENJA 10
5.1. Karakteristike najčešće korištenih alata za prevođenje 12
6. ANALIZA PRIMJERA PREVEDENOGA TEKSTA 15
7. ZAKLJUČAK 43
7.1. Ograničenja istraživanja 45
7.2. Prijedlozi za buduća istraživanja i primjenjivost rezultata 45
LITERATURA 46
SAŽETAK 48
ABSTRACT 49
ŽIVOTOPIS 50
8. PRILOZI 51

1. UVOD

Prevođenje je čin izvođenja poruke (misli, emocija, želja i uputa) s Alfa jezika na jezik Beta, ali s jednakom porukom [1]. Jezik koji se prevodi naziva se izvorni jezik (SL), a jezik na koji se prevodi, naziva se ciljni jezik (TL). Automatsko prevođenje s jednoga na drugi jezik *strojno prevođenje* nekoć je bila znanstvena fantastika i dugoročni san znanstvenika od neizmjerno velike društvene, znanstvene i političke važnosti. Strojno prevođenje bilo je jedno od najranijih predloženih primjena digitalnih računala, no ispostavilo se da je pretvaranje ovoga sna u realnost mnogo teži, zahtjevniji, ali i na puno načina zanimljiviji zadatak no što se isprva mislilo. Premda nekolicina problema još nije riješena, strojno prevođenje do određenoga stupnja danas je ipak dio svakodnevice. Strojno je prevođenje pokušaj automatizacije čitavoga ili jednoga dijela procesa prevođenja s jednoga ljudskoga jezika na drugi. Prema [2], strojno je prevođenje najkorisnije u velikim organizacijama u kojima su za pripremu dokumenata korišteni relativno sofisticirani alati i prilikom čije je pripreme dokumenata prevođenje integrirano u sam proces. Prema [1], priroda procesa prevođenja sastoji se od triju točaka: a) treba se prevesti poruka, a ne tekst, b) prvo se poruka mora izraziti na jeziku Alfa, a zatim na jeziku Beta, c) poruka mora biti ista u oba jezika Alfa i Beta, to jest primatelj na jeziku Beta mora primiti jednaku poruku kao primatelj na jeziku Alfa. Slijedom toga, pitanje je ekvivalentnosti ključni koncept u teoriji prevođenja.

1. 1. Problematika istovrijednosti

Jednakovrijednost (ekvivalencija) je središnji koncept u teoriji prevođenja, no jednako tako, istovremeno je i kontroverzan. Pristupi problemu ekvivalencije mogu se drastično razlikovati: neki teoretičari prevođenje definiraju u smislu odnosa ekvivalencije [3-5], dok drugi odbijaju ekvivalenciju kao teorijski pojam tvrdeći da je ili irelevatno [6] ili čak štetno [7] za proučavanje prijevoda. Kako god bilo, ekvivalencija je nužan uvjet za prevođenje definirano kao veza između izvornoga i ciljnoga teksta pritom dopuštajući ciljnom tekstu da bude u obliku prijevoda izvornoga teksta. Ipak, istaknuta je kružnost prema kojoj bi ekvivalencija trebala definirati prevođenje, dok prevođenje definira ekvivalenciju [8]. Zagovornici

prevođenja temeljenoga na teoriji koncentrirali su se na razvoj tipologije ekvivalencije fokusirajući se pritom na rang (riječ, rečenica ili razina teksta) ili na vrstu značenja (konotativno, denotativno, pragmatično itd.).

Na bazi referencijalne ili denotativne ekvivalencije, pretpostavka je da se riječi iz obaju (polaznoga i ciljnoga) jezika odnose na istu stvar u stvarnome svijetu. Riječi iz obaju jezika koje povlače istu ili sličnu asocijaciju u umu osoba čiji je materinji jezik polazni ili ciljni odnose se na konotativnu ekvivalenciju. Kada su riječi iz obaju jezika korištene u istome ili sličnome kontekstu u svome jeziku, to nazivamo normativnom ekvivalencijom [5]. Primjerice, riječ brother (brat) ima četiri značenja u engleskom jeziku: a) čovjek ili dječak koji ima iste roditelje kao druga osoba, b) čovjek koji je član iste grupe kao vi ili osoba koja s vama dijeli interese, ili pak ima sličan način razmišljanja kao vi, c) koristi se kao titula za čovjeka, primjerice za monaha koji pripada vjerskoj organizaciji i d) ponekad ju koriste Afro-Amerikanci za druge Afro-Amerikance (neformalno). Neki autori [5] koriste termin pragmatična, dok drugi [4] rabe termin dinamična ekvivalencija i definiraju pojam objašnjavajući da se to odnosi na riječi koje u oba jezika imaju jednak utjecaj na čitača. S druge, pak, strane, kada riječi iz polaznoga i ciljnoga jezika imaju sličnu ortografsku i fonološku strukturu, takva se ekvivalencija naziva formalnom [9]. Također, proširuje se koncept ekvivalencije kako bi pokrio i sličnosti u toku informacija u oba jezika, kao i vezne uloge koje oba jezika imaju u tekstovima, što se naziva tekstualnom ekvivalencijom [9]. Međutim, nisu sve varijable relevantne prilikom prevođenja teksta, a uloga je prevoditelja da odluči koje bi konstatacije trebale imati prioritet u određenom vremenu, čime se stvara funkcionalna ekvivalencija [10].

1.2. Zadatak diplomskoga rada

U radu će se definirati pojam strojnoga prevođenja i objasniti temeljne karakteristike alata za strojno prevođenje. Metodom nasumičnoga odabira, sačinit će se korpus za analizu koji će se sastojati od nekoliko kraćih tekstova izvorno napisanih na engleskome jeziku. Nadalje, korpus čine tri teksta različitih vrsta – izvorni znanstveni rad, popularno-znanstveni i novinski članak. Odabrani će se tekstovi prevesti na hrvatski jezik koristeći se pritom besplatnim alatima za strojno prevođenje (Google translate, Bing translator i Yandex translate). Prevedeni će se

tekstovi usporedno analizirati na morfološkoj, sintaktičkoj, semantičkoj i leksičkoj razini na temelju čega će se vrednovati korišteni alati za strojno prevođenje.

1.3. Struktura diplomskoga rada

Rad je podijeljen u šest poglavlja i jedno potpoglavlje. Opisani su i objašnjeni osnovni pojmovi, karakteristike, povijest, svrha kao i sama analiza prijevoda tekstova. U prvome poglavlju opisan je nastanak kao i povijesni razvoj strojnoga prevođenja od samoga početka do danas. U drugome je poglavlju opisana važnost alata za prevođenje gledajući s komercijalne, znanstvene i filozofske strane, dok je u trećemu poglavlju opisana svrha. U četvrtome su poglavlju nabrojane karakteristike strojnoga prevođenja, a u potpoglavlju su opisane karakteristike najčešće korištenih alata za prevođenje. U petom, ujedno i posljednjemu poglavlju, analizirane su nasumično odabrane rečenice iz teksta koje su prevedene trima alatima za strojno prevođenje.

2. POVIJESNI RAZVOJ STROJNOGA PREVOĐENJA

Premda korijeni strojnoga prevođenja sežu još iz dalekoga sedamnaestoga stoljeća, kada su se pojavile ideje o univerzalnim i filozofskim jezicima, kao i o „mehaničkim“ rječnicima, ipak se do dvadesetoga stoljeća nisu pojavili praktični prijedlozi. Patent Francuza Artsrounija u 1933. godini bio je stroj opće svrhe koji je ujedno mogao funkcionirati i kao mehanički višejezični rječnik. Rus Trojanskij otišao je nešto dalje imajući na umu zamisli o kodiranju i interpretiranju gramatičkih funkcija koristeći „univerzalne“ simbole u višejezičnome uređaju za prevođenje. Booth i Weaver sastali su se 1946. godine i objedinili svoje ideje o korištenju računala za prevođenje prirodnih jezika. Kasnijih godina radilo se na morfološkoj analizi za mehanički rječnik. 1949. godine Weaver je, na temelju svoga znanja o kriptografiji (logička promjena podataka) statistici i jeziku, mnoge zaintrigirao time što je iznio i najveći očiti potencijalni problem – dvosmislenost [11]. 1952. godine održana je prva konferencija o strojnome prevođenju na kojoj su izneseni mnogi prijedlozi koji se tiču nužnoga uređivanja prije i nakon čina prevođenja te uporabe mikro-glosara koji bi umanjili problem dvosmislenosti birajući prilagođene leksičke jedinice ciljnoga jezika. Prva demonstracija sustava za strojno prevođenje, koja je privukla i veliku pozornost medija, održala se 1954. godine. Pažljivo odabranih 49 rečenica prevedeno je s ruskoga na engleski jezik koristeći pritom vrlo sužen rječnik od svega 250 riječi i samo 6 gramatičkih pravila. Premda je sustav imao malu znanstvenu vrijednost, ipak je privukao investitore koji su potpomogli daljnja istraživanja. Kada su istraživanja na polju strojnoga prevođenja otpočela, nije bilo puno pomoći tadašnjih lingvista. Posljedica je bila da su pedesetih i šezdesetih godina metode istraživanja gravitirale između, s jedne strane pokušaja i promašaja empirijskoga pristupa koji je često uključivao i statističke metode za „otkrivanje“ gramatičkih i leksičkih pravila koji bi se mogli primijeniti, i, s druge strane, teorijskih pristupa koji su uključivali projekte u fundamentalnim lingvističkim istraživanjima [11]. Prvi model od triju osnovnih pristupa strojnome prevođenju, poznat i kao model „direktnog prijevoda“, uključivao je programska pravila razvijena za prijevod s jednoga polaznoga na jedan konkretan ciljni jezik s minimalnom količinom analize i sintaktičke reorganizacije. Problem homonima i dvosmislenosti nastojao se izbjeći pojednostavljivanjem dvojezičnih rječnika, tj. na način da

bude ponuđen samo jedan ekvivalent riječi u ciljnome jeziku. Drugi je pristup bio „međujezični“ model temeljen na apstraktnome prikazu (kodovi ili simboli za oba jezika) gdje bi se prijevod odvijao u dvjema fazama – od polaznoga jezika k međujeziku te od međujezika do ciljnoga jezika. Treći je pristup bio manje ambiciozan – tzv. „prijelazni pristup“ u kojemu je konverzija bila kroz prijelazni stadij od apstraktnoga prikaza teksta u polaznome jeziku do ekvivalenta u ciljnom. U ovome slučaju, prijevod je obuhvaćao tri stadija – analiza, transfer te sinteza [11]. U većini slučajeva prihvaćan je pristup direktnoga prijevoda često pritom koristeći statističke analize stvarnih tekstova za formiranje rječnika i pravila u njemu. Iz političkih i vojnih razloga, gotovo sva američka istraživanja bila su rusko-engleski prijevodi jednako kao što su i sva sovjetska istraživanja bila fokusirana na englesko-ruske sustave. Istraživanja koja je vodio E. Reifler fokusirala su se na direktni pristup temeljen na rječniku. To je uključivalo izradu velikih dvojezičnih rječnika u kojima leksikografske informacije nisu bile korištene samo za odabir leksičkih ekvivalenata, već i za rješavanje gramatičkih problema bez korištenja sintaktičke analize. Veliki broj znanstvenika toga vremena gajilo je nepovjerenje prema lingvističkoj teoriji; tada su jezičari Z. Harris i N. Chomsky tek započeli sa svojim radom. Radile su se statističke analize tekstova na ruskome jeziku te su se na taj način nadopunjavali dvojezični rječnici i gramatičke informacije. Na taj način moguće je bilo dobiti samo vrlo grube prijevode. Istraživač L. Dostert [12] radio je empirijske analize tek kada bi tradicionalne informacije o gramatici bile nedostatne. Otprilike u to vrijeme formirale su se i četiri grupe znanstvenika u SAD-u koji su se razlikovali po stajalištima i metodama rada. Na području bivšega Sovjetskoga Saveza, istraživanja su se provodila u jednako velikoj mjeri kao i u SAD-u te su pokazivala sličnosti s američkim po pitanju miješanja empirijskoga i osnovnoga teorijskoga pristupa. Do sredine šezdesetih godina, skupine istraživača strojnoga prevođenja utemeljile su se u čitavome svijetu (Kina, Meksiko, Japan) uključujući i većinu europskih zemalja (Mađarska, Čehoslovačka, Bugarska, Belgija, Njemačka, Francuska itd.) [13]. Pedesetih godina prošloga stoljeća, optimizam je bio vrlo velik premda su se mnogi složili da su istraživanja dosegnula određenu semantičku barijeru. Dani su primjeri problema za koji istraživači još uvijek nisu imali rješenje [14]. Rečenica *The box was in the pen* može biti potencijalni uzrok poteškoća jer riječ *pen* ima minimalno dva značenja - olovka ili kavez/gajba za životinje/djecu. Imajući znanja o realnom svijetu i veličini predmeta, jasno nam je da rečenica može biti prevedena jedino kao *Kutija je u kavezu.* Ovom demonstracijom htio je pokazati da ne postoji način na koji bi ijedno računalo ikada moglo riješiti situacije

koje zahtijevaju znanje o stvarnom svijetu. 1964. godine sazvan je savjetodavni odbor za automatsko procesuiranje jezika [15]. Zaključak koji je tada donesen jest da je strojno prevođenje sporije, manje točno i duplo skuplje od ljudskoga prevoditelja te da nema potrebe za daljnje financiranje istraživanja. Premda istraživanja nisu u potpunosti prestala, nastupilo je tiho desetljeće (1967.-1977.). Nakon 1977. godine, sve je više sustava svojim pojavljivanjem plijenilo pozornost javnosti. Od većega značaja bile su prve *Systran* instalacije, dok se početkom osamdesetih godina nije pojavila konkurencija korporacije *Logos* koja se većinom bavila prevođenjem uputa za korištenje letjelica. Krajem istoga desetljeća, pojavio se *METAL* koji se bazirao na prevođenju između engleskoga i njemačkoga jezika. Prema [16], METAL je originalno bio nazvan *Linguistics Research System* (LRS) – sustav za linvistička istraživanja, no kasnije je preimenovan u METAL (Mechanical Translation and Analysis of Languages – Strojno prevođenje i analiza jezika). Tijekom spomenutoga desetljeća, najveća komercijalna primjena strojnoga prevođenja odvijala se u Japanu gdje je većina računalnih tvrtki razvila softver za prevođenje, uglavnom za englesko-japanski i japansko-engleski prijevod.

Povratak istraživanjima bio je karakterističan po univerzalnome prihvaćanju pristupa koji se odvijao u trima stadijima te koji je osnovan formaliziranjem leksičkih i gramatičkih pravila pod utjecajem lingvističkih teorija toga vremena. Prema [11], jedan od najpoznatijih projekata bio je *Eurotra* čiji je cilj bio izraditi napredni višejezični sustav za prevođenje među europskim jezicima.

Tijekom vremena, prevoditeljima je postalo jasno da od strojnoga prevođenja imaju širok spektar koristi; od prijevoda ključnih riječi pa do izrade glosara. Međutim, nisu bili zadovoljni kvalitetom teksta koji su proizvodili sustavi za strojno prevođenje. Bilo je jasno da su htjeli imati pod kontrolom čitav proces, a ne biti robovima automatskoga sustava. Ranih devedesetih, pojavio se najznačajniji pomak dotad u vidu integriranih alata - tzv. stanica za prevoditelje.

Najdramatičnije razdoblje u razvoju bio je povratak pristupa temeljen na statistici (bez primjene lingvističkih pravila) percipiran kao povratak empirizmu i opreka dotadašnjemu racionalizmu. Drugi je veliki korpusni pristup temeljen na primjeru ili memoriji. Polazna je pretpostavka da prijevod često uključuje pronalazak analognoga primjera, tj. na koji je način određena riječ ranije prevedena. Premda je glavna inovacija od 1990. godine bila porast

pristupa baziranih na korpusu, ipak su i pristupi bazirani na pravilu zauzeli svoja mjesta, kako kod transfernih, tako i kod međujezičnih sustava [16].

3. VAŽNOST AUTOMATIZACIJE PREVOĐENJA

Pitanje je strojnoga prevođenja nedvojbeno važno, što god pojedinac mislio i kakve god unutarnje interese imao. Tema je nesumnjivo važna, kako s društvenoga, političkoga i komercijalnoga, tako i znanstvenoga, intelektualnoga i filozofskoga gledišta. Društvena i politička važnost strojnoga prevođenja polazi od društveno-političke važnosti prevođenja u zajednicama u kojima se općenito govori više od jednoga jezika. U tom slučaju, jedina vidljiva alternativa prevođenju bila bi uvođenje i prihvaćanje jednoga zajedničkoga jezika *lingua franca* koji, bez obzira na to kako se na prvu čini, nije posebno privlačna opcija jer uključuje dominaciju odabranoga jezika, što predstavlja nedostatak govornicima drugih jezika marginalizirajući ih. Umanjivanjem važnosti određenoga jezika, javlja se potencijalni rizik od izumiranja dotičnih jezika. Dakle, prevođenje je nužno za komunikaciju - kako za svakodnevnu komunikaciju pripadnika društva, tako i za skupljanje informacija potrebnih pojedincu kako bi se u potpunosti integrirao u društvo. Potpuno je pravo, ali, nažalost, često zanemareno, svakoga pojedinca izražavati se i primati informacije na svome jeziku. Ponekad to ovisi upravo o dostupnosti i pristupu prevođenju. Problem je u tome što je potreba za prevođenjem u modernome svijetu toliko velika da nadilazi realne mogućnosti. Dio je problema i u tome što u svijetu ne postoji toliko velik broj prevoditelja i što je njihova učinkovitost smanjena bez automatizacije jednako kao što je i postavljena granica njihovoj produktivnosti. Ukratko, čini se da je automatizacija prevođenja u modernome svijetu društvena i politička potreba za zajednice koje ne žele nametati svojim pripadnicima zajednički jezik [17].

Komercijalna važnost strojnoga prevođenja rezultat je međusobno povezanih čimbenika. Prvo, prevođenje je samo po sebi komercijalno važno. Suočeni s odlukom između proizvoda s uputama za korištenje na engleskom i onoga s uputama na japanskom, većina će engleskih govornika kupiti prvi proizvod s uputama za korištenje na svome jeziku. Drugo, prevođenje je

skupo. To je posao koji zahtjeva velike vještine i znanje koje daleko premašuje samo poznavanje više jezika.

Gledajući iz znanstvene perspektive, strojno je prevođenje vrlo zanimljivo jer je očita primjena i testno tlo za razne ideje u računalnoj znanosti i umjetnoj inteligenciji. Prema [2], umjetna inteligencija grana je računalne znanosti koja se bavi simulacijom aspekta ljudske inteligencije poput razumijevanja, produciranja jezika, planiranja i lingvistike. Neki od najvažnijih razvitaka na tim područjima započeli su upravo strojnim prevođenjem.

S filozofskoga gledišta, strojno je prevođenje zanimljivo jer predstavlja pokušaj automatizacije aktivnosti koja može (i često mora) zahtijevati širok spektar ljudskoga znanja. Jedan jednostavan primjer bio bi prijevod sintagme s engleskog „negatively charged electrons and protons“ na hrvatski kao „negativno nabijeni elektroni i negativno nabijeni protoni“, što je pogrešno, jer protoni su pozitivno nabijene čestice. Dakle, zaključujemo da je za prevođenje potrebno puno više znanja od poznavanja dvaju ili više jezika. Postavlja se pitanje do koje se granice može automatizirati prevođenje, odnosno koliko se može automatizirati razmišljanje.

4. SVRHA STROJNOGA PREVOĐENJA

Većina prijevoda u svijetu nisu tekstovi od kulturnoga i literarnoga značaja. Velika većina profesionalnih prevoditelja zaposleni su kako bi zadovoljili goleme i, k tomu još, rastuće potrebe za prijevodima znanstvenih i tehničkih dokumenata, komercijalnih i poslovnih spisa, pravne dokumentacije, uputa za korištenje, poljoprivrednih i medicinskih udžbenika, novinskih izvještaja itd. Jedan dio takvoga posla može prevoditelju predstavljati izazov, ali većina je teksta ponavljanje, dok u isto vrijeme zahtijeva točnost i dosljednost. Zahtjevi su za takvim prijevodima u porastu daleko većem, negoli što je kapacitet prevoditelja. Jasno je da je pomoć računala u tome slučaju više nego dobrodošla. Praktična korist sustava za prevođenje određena je kvalitetom dobivenoga sadržaja. No, zaista je teško definirati „dobar“ prijevod, bilo da se radi o prijevodu koji je načinio prevoditelj ili alat za prevođenje. To uvelike ovisi o određenim okolnostima u kojima je izrađen, kao i o klijentu za kojega je rađen. Razni su kriteriji koji odlučuju, no vrlo su subjektivni. Najveće su prepreke kod strojnoga prevođenja lingvističke. To su problemi leksičke dvosmislenosti, sintaktičke kompleksnosti, razlike u vokabularu između jezika i gramatičke konstrukcije. Strojno prevođenje ne može izravno primijeniti lingvističke teorije; lingvisti se bave objašnjenjima mehanizama proizvodnje jezika fokusirajući se pritom na krucijalne karakteristike. Sustavi za prevođenje, s druge strane, moraju se suočiti sa stvarnim tekstovima i raznim lingvističkim fenomenima, kompleksnosti terminologije i neologizmima [2].

5. KARAKTERISTIKE STROJNOGA PREVOĐENJA

„Strojno prevođenje je gubitak vremena jer nikada se neće proizvesti stroj koji će prevoditi Shakespearea“ [2]. Kritika o nemogućnosti prevođenja beletristike strojnim prevođenjem vjerojatno je točna, ali jednako je tako i promašena bit. Prije svega, treba naglasiti da prevođenje lijepe književnosti zahtijeva posebne vještine lijepoga izražavanja i nije zadatak kojega svaki prevoditelj može uspješno obaviti baš zbog toga što zahtijeva umijeće vladanja riječima. Nadalje, tekstualnih sadržaja lijepe književnosti daleko je manje u stvarnosti, stoga prihvaćanje kritike i dalje ne znači da je strojno prevođenje beskorisno. Naposljetku, valjalo bi se zapitati zašto bi uopće itko želio prevoditi Shakespeareova djela strojnim putem jer to je posao koji je vrlo zahtjevan i ljudima koji se bave prevođenjem te nipošto nije rad za koji je strojno prevođenje namijenjeno. To je kao da kritiziramo robote jer nisu sposobni plesati balet. Jednostavno, to im niti nije namjena. Naravno, činjenica je da je kvaliteta određenoga broja sustava strojnoga prevođenja još uvijek slaba i vjerojatno niti jedan postojeći sustav ne može proizvesti savršen prijevod. No, to i dalje ne čini strojno prevođenje beskorisnim.

Valja istaknuti činjenicu da ne treba svaki prijevod biti savršen. Zamislimo da pred nama stoje kineske novine za koje smatramo da mogu sadržavati informaciju od iznimne važnosti za našu tvrtku. Čak bi nam i vrlo grub prijevod u takvoj situaciji bio od velike pomoći. Bilo bi posve dovoljno i da takvim prijevodom samo steknemo uvid u to koji bi dio novina valjalo detaljno prevesti. Još jedna važna činjenica jest da ni ljudski prevoditelji ne omogućuju savršen prijevod odmah. Normalno je da se proces prevođenja dijeli u dva stadija - prvi je grubi prijevod na ciljni jezik u kojemu su razriješene najveće teškoće i odabir ključnih termina i riječi, ali koji uglavnom nije savršen. U drugome stadiju, koji obavlja isti ili ponekad drugi prevoditelj, radi se na uljepšavanju teksta i prilagođavanju očekivanome. To može uključivati samo provjeru ili pak veće izmjene u svrhu poboljšanja kvalitete kako bi izgledalo kao da je originalno pisano na ciljnome jeziku. Većinom je svrha strojnoga prevođenja samo automatizacija prevoditeljskoga procesa u prvome stadiju prilikom izrade gruboga prijevoda. Strojno je prevođenje korisno. Naime, METEO je jedan od prvih operativnih sustava za strojno prevođenje posebno dizajniran za prijevod vremenskih prognoza (u svrhu prijevoda s francuskog na engleski u kanadskoj pokrajini Quebec). U uporabi je od 1977. godine [2].

Osamdesetih godina prošloga stoljeća proizvođač dizel motora Perkins Engines štedio je oko četiri tisuće funti i do 15 tjedana vremena na svakoj prevedenoj uputi za korištenje.

Premda sustavi za strojno prevođenje ponekad proizvedu besmislice za dotičan kontekst, postoje razne situacije u kojima je sposobnost sustava za prevođenje da proizvedu pouzdane i brze prijevode vrlo korisna i cijenjena. U nekim okolnostima, sustavi za strojno prevođenje mogu proizvesti sadržaj zaista dobre kvalitete - manje od 4 % sadržaja prevedenoga METEO sustavom zahtjeva neku ljudsku korekciju [2]. Čak i ukoliko kvaliteta dobivenoga teksta nije sjajna, ipak je brže i jeftinije ispraviti eventualne pogreške i dotjerati tekst nego prevoditi kompletan tekst „ručno“.

Strojno prevođenje ni na koji način ne ugrožava posao prevoditelja. Potreba za prevođenjem nepresušna je, a granice trenutnih sustava za prevođenje još su prevelike. Kakogod, sustavi ipak mogu preuzeti dio dosadnih, ponavljajućih poslova prevoditelja i time omogućiti prevoditelju da se usredotoči na zanimljivije zadatke u kojima će biti potrebne njegove specifične vještine.

Postoje mnoga otvorena pitanja kada se radi o rješavanju postojećih problema vezanih za približavanje sposobnosti sustava ljudskim prevoditeljima. Međutim, ne samo da postoje mnoga otvorena pitanja kada se radi o istraživanju sustava strojnoga prevođenja, nego je i sam proces stvaranja takvoga sustava vremenski vrlo dugotrajan proces koji nužno uključuje i doprinos gramatičara te raznih jednojezičnih i dvojezičnih rječnika. Za to jednostavno ne postoji čarobno rješenje. U praksi, prije nego sustav za strojno prevođenje postane koristan, korisnik uglavnom mora uložiti izvjesnu količinu vremena i truda prilagođavajući ga.

Strojno prevođenje započeto je s nadom i očekivanjem da će većina rada kod prevođenja biti obavljena tako da se prevoditelj rastereti i posao preuzme sustav koji bi sadržavao sve informacije kao i klasični dvojezični rječnik. Riječi polaznoga jezika bile bi zamijenjene njihovim ekvivalentima u ciljnome jeziku, kako je unaprijed određeno ugrađenim rječnikom, i gdje bi poredak riječi u rečenicama na polaznome jeziku bio izmijenjen na određeni način i prema posebnim pravilima karakterističnima za ciljni jezik. Točni prijevodi pogodni za korištenje bili bi izneseni prethodno obavivši dva jednostavna koraka. Ovo korespondira s mišljenjem da prijevod nije ništa drugo negoli jednostavna zamjena riječi iz polaznoga jezika riječju u ciljnom jeziku te potom eventualna promjena redoslijeda riječi u rečenici prema ustaljenim pravilima.

Prevođenje teksta ne zahtijeva samo dobro poznavanje rječnika obaju jezika, nego i gramatike - sustava pravila koji određuje koje su rečenice valjano strukturirane u određenome jeziku. Također, prevođenje zahtijeva i određenu količinu znanja o svijetu koji nas okružuje - znanje o prirodi stvari i njihovu zajedničkome funkcioniranju [18]. Znanstvenici i istraživači vjeruju da mnogo toga može biti učinjeno kako bi se ti zahtjevi zadovoljili, no proizvodnja sustava koji će to zaista u praksi i omogućiti nije nimalo jednostavan zadatak.

Mehanizacija prevođenja jedan je od najstarijih snova čovječanstva. U dvadesetome stoljeću, taj je san pretvoren u stvarnost u obliku računalnih programa koji su sposobni prevesti širok spektar tekstova s jednoga prirodnoga jezika na drugi. No, kao i uvijek, stvarnost nije savršena. Ne postoje „strojevi za prevođenje“ koji će jednim klikom pretvoriti tekst na jednom jeziku u savršen tekst na drugome bez intervencije i pomoći čovjeka. Zasad je to samo cilj za neku daleku budućnost premda mnogi sumnjaju u mogućnost ostvarenja takve zamisli. Ono što, međutim, je postignuto jest razvitak programa koji mogu dati „sirove“ ili grube prijevode tekstova koji potom mogu biti razrađeni i oblikovani u duhu ciljnoga jezika i to o smanjenome trošku ili koji i u neobrađenome obliku mogu poslužiti svrsi pojedincima upoznatima s materijom.

Postignuća strojnoga prevođenja uključuju i proizvodnju tekstova više kvalitete kojima nije potrebno preoblikovanje i dotjerivanje uz prethodne preinake teksta na polaznome jeziku. Kako bilo, strojno je prevođenje često pogrešno shvaćeno. Percepcija javnosti često je pogrešna i ide u dvije krajnosti. S jedne strane, postoji skupina ljudi koja smatra da nema ništa teško u analiziranju jezika budući da su i mala djeca sposobna producirati jezik i s lakoćom usvajati strane jezike. Takvi su uvjereni da svi ljudi koji imaju znanje dvaju stranih jezika mogu bez poteškoća prevoditi. Posljedično, ne cijene svi trud, rad i uloženo vrijeme prevoditelja. S druge, pak, strane, postoje i ljudi koji vjeruju da, s obzirom da automatsko prevođenje Shakespearea, Tolstoja ili Goethea nije moguće, ni strojno prevođenje nema nikakvu svrhu. Oni nisu sposobni cijeniti doprinos koji nesavršeni prijevod može dati što njima osobno, što općenito društvu u poboljšanju međunarodne komunikacije [16].

5.1. Karakteristike najčešće korištenih alata za prevođenje

Najčešće su korišteni alati za strojno prevođenje *Google Translate, Bing Translator, Linguee, WordLens, Yandex, SDL Trados Studio, Fluency Now, ProZ, MemoQ, Memsource* itd. [19]. U ovome će radu naglasak biti na *Bing*, *Yandex* i *Google*, jer, osim što su jedni od najčešće korištenih alata, oni su i besplatni te nude mogućnost prijevoda s engleskoga na hrvatski jezik. Bing [20] je tražilica u vlasništvu Microsofta i uključuje i portal za prevođenje tekstova ili čitavih internetskih stranica na razne jezike. Prevođenje omogućava Microsoft Translator; platforma i internetska usluga za statističko strojno prevođenje koju je razvio Microsoft Research. Od lipnja 2017. godine, Bing prevoditelj nudi mogućnost prijevoda na 60 različitih jezika. Bing može prevoditi fraze koje korisnik samostalno unese ili korisnik može unijeti poveznicu na internetsku stranicu koja će potom u potpunosti biti prevedena. Prilikom prevođenja cijele internetske stranice, ili ukoliko korisnik odabere opciju *Prevedi ovu stranicu*, u rezultatima pretrage Bing tražilice, pojavljuje se dvojezični preglednik koji korisniku omogućuje pretraživanje teksta na izvornoj internetskoj stranici paralelno s prijevodom [20].

Microsoft Translator višejezični je mrežni servis za strojno prevođenje. Integriran je u razne razvojne programe i gospodarske proizvode uključujući Bing, Microsoft Office, Skype Translator, Internet Explorer, iPhone i Apple sat, Android telefon itd. Microsoft Translator nudi mogućnost prijevoda teksta i govora putem poslovne usluge oblaka API. Usluga prevođenja teksta proteže se od besplatne, koja podržava dva milijuna znakova mjesečno, pa do plaćenih kojima korisnik može prevoditi milijarde znakova svakoga mjeseca. Govorno prevođenje, pušteno u uporabu u ožujku 2016. godine, obračunava se prema vremenskome trajanju audio sadržaja te besplatno omogućuje dva sata prijevoda mjesečno, a plaćeno i do sto sati. Usluga omogućuje rad sa 60 jezičnih sustava, a podržava i 10 sustava za govorno prevođenje, što izvrsno služi Skype Translatoru i Microsoft aplikacijama za iOS i Android.

Uz Bing, drugi najpoznatiji online prevoditelj svakako je Google translate [21]. Usporedivši ova dva prevoditelja, najočitija je razlika u broju podržanih jezika. U ovome trenutku, Google radi s 90 jezika i taj je broj u neprestanome porastu, dok Bing trenutno podržava ukupno 51 jezik. Po pitanju točnosti, oba su osrednja bez prevelikih razlika. Google Translate, za razliku od nekih sustava, ne nudi mogućnost probe prije kupnje [21].

Yandex [22] je prevoditelj usluga koju pruža ruski Yandex, a svrha je prijevod tekstova i internetskih stranica. Sustav se temelji na statističkome strojnome prevođenju kojega je razvio sam Yandex. Sustav sadrži rječnik nastao prilikom analiziranja milijuna različitih prijevoda.

Kako bi prevelo tekst, računalo potraži ekvivalent u već postojećemu modelu s ciljem pronalaska značenja određenoga izraza u danome kontekstu. Nadalje, prevoditelj je ugrađen u Yandex tražilicu i automatski nudi prijevod teksta na neki od podržanih stranih jezika. Nakon lansiranja sustava 2011. godine, jedini podržani jezici bili su engleski, ruski i ukrajinski, a do sad je prijevod omogućen na čak 94 jezika [23].

Napravljena je paralelna usporedba nekoliko alata za strojno prevođenje [24] prilikom čije ćemo se analize usredotočiti na Bing i Google. Broj polaznih jezika kod Binga je 45, dok Google raspolaže s njih čak 64. Broj ciljnih jezika kod Binga jest 44, a Googlea 90. Bing nudi opciju besplatnoga isprobavanja za manje od 2 milijuna znakova, dok Google nema takvu opciju te je općenito mjesečni iznos veći nego Bingov ovisno o broju milijuna znakova. Kada se radi o performansama, kreiran je relativno zahtjevan odlomak teksta u testne svrhe. Odlomak je sadržavao složenice, idiome, riječi koje nemaju točan ekvivalent u ciljnome jeziku i višeznačne riječi. Prevođenje se odvijalo s engleskoga na španjolski. Rezultati pokazuju da Bing nije imao problema s prevođenjem složenica, dok je idiom preveo doslovno. Ponudio je najbolju alternativu riječi bez ekvivalenta te točno preveo višeznačnu riječ značenja. Google je imao najslabije rezultate na testu. Idiom je također preveo doslovno, što je i bilo očekivano. Prijevod riječi bez ekvivalenta u ciljnome jeziku bio je zadovoljavajući i nije bilo teškoća s prijevodom višeznačne riječi. Zaključak je da su svi alati podbacili na ovome testu premda treba uzeti u obzir da je test bio stvoren tako da bude zahtjevan i izazovan na razne načine. Prijevodi su bili jedva razumljivi, posebice ukoliko korisnik nije naviknut na prijevode alata za strojno prevođenje. Premda su svi alati otprilike na podjednakoj razini po kvaliteti dobivenoga sadržaja, ipak, uzevši u obzir kriterij razumljivosti, pobjedu odnosi Bing.

6. ANALIZA PRIMJERA PREVEDENOGA TEKSTA

Za prijevod tekstova odabrana su tri besplatna alata za strojno prevođenje, a to su *Google Translate, Bing Translator* i *Yandex Translate*. Metodom nasumičnoga odabira bit će analizirano 15 rečenica iz triju tematski različitih vrsta radova – izvorni znanstveni članak, popularno-znanstveni članak i novinski članak. Rečenice su analizirane na morfološkoj, sintaktičkoj, semantičkoj i leksičkoj razini.

Tablica 6.1. Primjer prevedene rečenice broj 1.

(1) An Uber executive accused of stealing driverless car technology from his former employers at Google is exercising his Fifth Amendment right to avoid self-incrimination, according to his lawyers.	
GOOGLE TRANSLATE 1a)	Uber izvršni optužen za krađu automobilske tehnologije bez vozača od njegovih bivših poslodavaca u Googleu provodi svoje pravo peti amandmana kako bi izbjegao samoubojstvo, prema njegovim odvjetnicima.
BING TRANSLATOR 1b)	Uber izvršni optužen za krađu Svjetlopropusni automobila tehnologija od svojih bivših poslodavaca na Google je vježbanje desnoj peti amandman kako bi se izbjeglo samooptuživanja, prema njegovi odvjetnici.
YANDEX TRANSLATE 1c)	Izvršni uber optužen za krađu tehnologije bez posade vozila od svog bivšeg poslodavca u Google koristi svoje pravo na peti

	amandman, kako bi se izbjeglo самооговора, prema riječima njegovog odvjetnika.

U primjeru rečenice broj 1, načinjeno je nekoliko pogrešaka alata za strojno prevođenje. Riječ *executive* može biti pridjev koji je najčešće nalazi ispred neke imenice i prevodi se s riječju *izvršan*. Također, *executive* može biti i imenica i označava *rukovoditelja/izvršitelja* određene radnje. Uspoređujući primjer svih triju alata za strojno prevođenje, vidimo da se pogrešan izbor vrste riječi ponavlja, što ukazuje na to da programeri nisu predvidjeli sve moguće situacije uporabe riječi *executive* i time onemogućili alate za pravilno prevođenje iste.

To exercise one's Fifth Amandement right trebalo bi se prevesti kao *korištenje prava na Peti amandman*, što je dobro prevedeno samo kod Yandex alata 1c) i djelomično prihvatljivo kod Google prevoditelja 1a), dok je kod Binga 1b) doslovno upotrjebljen glagol *exercise*, čime je načinjena greška na leksičkoj razini. Iako je u izvorniku *Fifth Amandement* vlastito ime, nijedan alat za strojno prevođenje ne prepoznaje to kao vlastito ime i koristi ga kao običan broj.

Kod alata Bing 1b) uočavamo nepotrebno dodavanje riječi *Svjetlopropusni* i *desnoj* koje ničemu ne odgovaraju izvorniku.

Imenica *self-incrimination* u hrvatskom se jeziku može prevesti kao *samooptuživanje* ili *samoinkriminacija*. Samo je alat Bing 1b) dobro preveo traženu riječ iako ju nije koristio u odgovarajućem padežu (samooptuživanje). Google 1a) je koristio posve drugu riječ (samoubojstvo) i time uvelike promijenio značenje cijele rečenice, dok kod Yandexa 1c) uočava problem korištenja neodgovarajućega pisma ćirilice i uporabe riječi *самооговора* koja je posve nerazumljiva govornicima hrvatskoga jezika.

Nadalje, i kod naizgled jednostavnih fraza poput *according to his lawyers*, uočavamo probleme kod alata za strojno prevođenje Bing 1b) i Yandex 1c). Kod alata Bing 1b) zabilježena je pogreška na morfološkoj razini jer riječi nisu pravilno deklinirane (prema njegovi odvjetnici), dok kod Yandexa 1c) bilježimo uporabu jednine (prema riječima njegovog odvjetnika) umjesto množine, čime se mijenja značenje izraza.

Tablica 6.2. Primjer prevedene rečenice broj 2.

(2) Camera based assistance systems for the blind and visually impaired are still in a preliminary stage.	
GOOGLE TRANSLATE 2a)	Sustavi pomoći za slijepe i slabovidne osobe koji se temelje na kameri još uvijek su u preliminarnoj fazi.
BING TRANSLATOR 2b)	Kamera na temelju pomoć sustava za slijepe i slabovidne osobe su još uvijek u pripremnoj fazi.
YANDEX TRANSLATE 2c)	Sustavi kamera sustava skrbi za slijepe i slabovidne još uvijek u preliminarnoj fazi.

Iako je *Primjer 2.* kratak i naizgled jednostavan za prijevod, prijevodi strojnih prevoditelja ukazuju na određene poteškoće. U prijevodu koji je rađen uporabom Google alata (2.a.) za strojno prevođenje, ne pronalazimo zamjerke, stoga možemo zaključiti da je prijevod Google alata za strojno prevođenje korektno preveo primjer rečenice broj 2.

Za razliku od prijevoda 2a), u prijevodu 2b) bilježimo nekoliko pogrešaka na morfološkoj i leksičkoj razini. Pogrešno je deklinirana riječ *pomoć*, odnosno uopće nije provedena deklinacije imenice, nego je imenica upotrjebljena u nominativnome obliku. Nadalje, prekršeno je pravilo sročnosti, odnosno slaganje riječi u rečenici prema gramatičkim kategorijama kao što su rod, broj i padež. Preciznije, imenica *kamera* koristi se u jednini dok se pomoćni glagol biti *…su još uvijek…* koristi u množini. Međutim, najveća je pogreška u odabiru riječi na početku rečenice. Naime, sustavi se pomoći za slijepe i slabovidne osobe temelje na kameri, a ne kamera na njima. Za razliku od prethodno spomenutih dviju grešaka

na morfološkoj razini, koje bi čitatelj lakoćom mogao otkloniti, posljednja pogreška mijenja značenje rečenice (a možda i ostatka teksta), što, osim nerazumijevanja sadržaja, može dovesti do pogrešnoga tumačenja sadržaja teksta.

U prijevodu 2c) izostavljen je pomoćni glagol biti u dijelu *…još uvijek u preliminarnoj fazi*. Dva se puta ponavlja imenica *sustav*, a posve je izostavljena imenica *pomoć*. Izbjegnuta je posljednja prijevodna pogreška iz primjera 2b); međutim, iz prijevoda se 2c) ne iščitava na koji su način kamera i sustavi pomoći slijepim i slabovidnim osobama povezani, stoga se može zaključiti da je prijevod, osim netočan, i nerazumljiv.

Tablica 6.3. Primjer prevedene rečenice broj 3.

(3) Imagine taking a time machine back to 1750—a time when the world was in a permanent power outage, long-distance communication meant either yelling loudly or firing a cannon in the air, and all transportation ran on hay.	
GOOGLE TRANSLATE 3a)	Zamislite uzimanje vremenskog stroja natrag do 1750. godine - vrijeme kada je svijet bio u stalnom nestanku struje, komunikacija na dalekoj udaljenosti značila je glasno vikati ili pucati u zrak, a sav prijevoz krenuo je na sijeno.
BING TRANSLATOR 3b)	Zamislite voditi vremenski stroj u 1750 — vrijeme kad je svijet bio u trajne struje na daljinu komunikacija mislio vikati glasno ili pucanje topova u zraku i svim prijevoza ran na sijeno.
YANDEX TRANSLATE 3c)	Zamislite automobil vremena još 1750—vrijeme, kada je svijet bio u stalnom nestanka struje, međugradske veze značilo ili glasno vikati ili pucnjava iz pištolja u zrak, i sva vozila naletio na sijeno.

Višesložne je sintagme i frazalne glagole vrlo teško prevoditi i zadržati isti broj riječi u izvorniku i prijevodu, stoga prevoditelji takve izraze često moraju opisno prevoditi i mijenjati redoslijed riječi u rečenici kako bi postigli cilj prijevoda – prenijeli poruku iz izvornika. Brojne su poteškoće zabilježene u prijevodima iz primjera 3).

Imagine taking a time machine back to 1750 trebalo bi se prevesti kao *Zamislite da vas vremenski stroj odvede nazad u 1750. godinu* što niti jedan od triju proučavanih alata za strojno prevođenje nije ispravno preveo. U prijevodu 3a), glagol *taking* doslovno je preveden kao *uzimanje,* što inače je jedan od prijevoda spomenutoga glagola, no ne u ovome kontekstu. Ovaj primjer pokazuje kako je za ispravan prijevod potrebno uzimanje konteksta u obzir, što alat za strojno prevođenje, barem u ovome slučaju, nije bio u stanju učiniti. Spomenuti je dio bio još problematičniji za alat Bing koji je zamijenio ulogu vršitelja i trpitelja radnje. Naime, u prijevodu 3b), pojedinac odi vremenski stroj u 1750. godinu, a ne obrnuto – vremenski stroj vodi pojedinca u 1750. godinu. S obzirom na opće znanje o radu vremenskih strojeva, čitatelja prijevod 3b) vjerojatno ne bi zbunio, no nikako nije adekvatan. Nadalje, osim što nedostaje prijedlog *iz* (iz 1750.), u prijevodu 3c) uočavamo zamjenu riječi *vremenski stroj* s *automobilom vremena*, što, osim što nije točno, ne postoji ni u jednome jeziku. Također, u prijevodima 3b) i 3c) zabilježena je gramatička pogreška neuporabe pravopisnoga znaka točke iza rednoga broja 1750.

Dio rečenice *…a time when the world was in a permanent power outage…* pravilno je prevedeno samo u prijevodu 3a), dok je u prijevodu 3c) prijevod per se pravilan, no imenica *nestanka* nepravilno je deklinirana (nestanku). Prijevod iz 3c) *vrijeme kad je svijet bio u trajne struje* sadrži riječi koje ne postoje (trajne struje) i potpuno je nerazumljiv čitatelju.

Sljedeći dio rečenice *…long-distance communication meant either yelling loudly or firing a cannon in the air…* pravilno je preveden u prijevodu 3a) s tim da nedostaje riječ *top* (pucati u zrak iz topa). U prijevodu 3b), bilježimo doslovan prijevod sintagme *long-distance communication* (na daljinu komunikacija), dok se u prijevodu 3c) koristi pogrešna riječ *međugradska veza*. Komunikacija na daljinu, dakako, može biti međugradska komunikacija; međutim, sintagma *međugradska komunikacija* hiponim je u odnosu na hiperonim *komunikacija na daljinu*, odnosno međugradska je komunikacija uži pojam i ne pokriva u potpunosti komunikacija na daljinu. Nadalje, u prijevodu 3b) ne koriste se bezlične strukture

infinitiva *glasno vikati* ili glagolske imenice *glasno vikanje*, nego se naznačava vršitelj radnje u muškome rodu *mislio*, dok je u prijevodu 3c) kombinacija spomenutih infinitiva *glasno vikati* i imenice *pucnjava*, što je strukturalno pogrešno. Za razliku od prijevoda 3a) gdje je izostavljena imenica top, u prijevodu se 3b) imenica koristi, no pogrešno je deklinirana imenica *zrak*, što daje značenje da su topovi smješteni na visini i pucaju u zraku, a ne u zrak. Posljednja se greška ne nalazi u prijevodu 3c), no u njemu je upotrjebljena pogrešna imenica *pištolj* umjesto *top*.

U posljednjemu dijelu rečenice *…all transportation ran on hay* prijevod je trebao biti *sav je prijevoz bio na sijeno.* Uporabom glagola *krenuti* u prijevodu 3a), može se zaključiti da su sva prijevozna sredstva krenula u nekome smjeru, a cilj je bio sjeno, a ne da je sredstvo pogona bilo sijeno. Višeznačnost glagola *run* stvorila je probleme i kod ostalih alata za strojno prevođenje. U prijevodu 3b), alat Bing uopće nije preveo glagol, nego ga je ostavio u izvornome obliku, dok je alat Yandex uporabom glagola *naletjeti* promijenio značenje rečenice navodeći čitatelja na zaključak o prometnoj nesreći. Isti je alat riječ *transportation* pogrešno preveo imenicom *vozila*, što je sredstvo prijevoza, a ne sam prijevoz.

Tablica 6.4. Primjer prevedene rečenice broj 4.

(4) The lawyers for Anthony Levandowski, the former head of Google's self-driving car project who is now leading a similar effort at Uber, said he was broadly asserting his Fifth Amendment rights because there was "potential for criminal action" in the case, according to court transcripts obtained on Thursday.	
GOOGLE TRANSLATE 4a)	Odvjetnici za Anthony Levandowski, bivši šef Googleovog autoprojekta koji sada vodi sličan napor u Uberu, izjavio je da široko tvrdi svoje pravo peti amandmana jer je u tom slučaju "potencijal za kazneno djelo", prema Sudski zapisi dobiveni u četvrtak.

BING TRANSLATOR 4b)	Odvjetnici za Anthony Levandowski, bivši šef Google samostalno vozi auto projekt koji je sada vodeći sličan napor na Uber, rekao je on široko govori njegov peti amandman prava zato što je "potencijal za kriminalnih akcija" u slučaju, prema sudskih zapisnika dobivenih u četvrtak.
YANDEX TRANSLATE 4c)	Odvjetnici Ante Левандовского, bivši šef Google samostalno vožnje automobila projekta, koji sada vodi sličnu aktivnost u ladicu, rekao je da je bio široko tvrdeći da je njegov peti amandman prava, jer nije bilo "mogućnosti za kriminalne aktivnosti" u slučaju da, prema sudskim protokolima su dobiveni u četvrtak.

U prijevodima primjera 4) nalazimo pogreške na svim jezičnim razinama. *The lawyers for Anthony Levandowski* doslovno je preveden u prijevodu 4a) i 4b), odnosno prijedlog *za* ne bi se trebao koristiti u prijevodu koji bi trebao glasiti *Odvjetnici Anthonyja Levandowskoga*. Prijevod 4c) najbliži je ciljnom prijevodu; međutim, ime i prezime spomenute je osobe pogrešno. Naime, osobna se imena ne prevode, a u prijevodu 4c) osobno ime *Anthony* naturalizirano je i prevedeno na hrvatski jezik kao *Ante*. Za razliku od imena, prezime nije naturalizirano, nego je napisano pismom ćirilicom koja se ne koristi u hrvatskome jeziku i koju većina populacija, posebno mlađe, uopće ne zna čitati.

…the former head of Google's self-driving car project… nastavak je rečenice i odnosi se na Anthonyja Levandowskoga, stoga je *bivši šef* trebalo pravilno deklinirati u *bivšeg šefa*, što nijedan alat za strojno prevođenje nije učinio. *Google's self-driving car project* je *Googlev projekt samovozećega automobila*. Dok je prijevodu 4a) jasno da se radi o projektu automobila, iako je izostavljena ključna riječ *samovozeći*, u prijevodu 4b) čitatelja se pogrešno upućuje da Levandowski samostalno vodi projekt automobila. Prijevod 4c) toliko je pogrešan da čitatelj ništa ne može shvatiti iz njega, odnosno taj je dio rečenice u potpunosti nerazumljiv čitatelju.

…who is now leading a similar effort at Uber… trebalo je glasiti *…koji sada vodi ulaže jednaki napor/vodi sličan projekt u Uberu…* Iako se koristeći imenicu *napor* može prenijeti smisao, ljudski bi se prevoditelj vjerojatno odlučio na uporabu imenice *projekt* jer bi se njome posve prenijelo značenje toga dijela rečenice. Prijevod je 4a) korektan, dok se u prijevodu 4b) nepravilno koristi prijedlog *na* budući da se aktivnosti vode u Uberu koji je tvrtka. U prijevodu 4c) imenica *napor* zamijenjena je imenicom *aktivnost*, što može funkcionirati, no izostavljeno je ime tvrtke *Uber* umjesto koje je korištena imenica *ladica* za čiju uporabu ne postoji opravdan razlog i čini prijevod nerazumljivim.

Iako je najčešće značenje priloga *broadly široko*, u ovome se kontekstu ne može primijeniti, odnosno trebao bi se koristiti prilog *potpuno*. Svi su alati za strojno prevođenje upotrijebili najčešći prijevod spomenutoga priloga, što, kao i u primjeru 1), ponovo ukazuje na to da programeri nisu predvidjeli više prijevodnih mogućnosti ovisno o kontekstu uporabe. *To assert rights* trebalo bi se prevesti kao *koristiti prava*, što nijedan alat za strojno prevođenje nije upotrijebio ponovo koristeći glagole *tvrditi* ili *govoriti* koji su tipičniji prijevodi glagola *assert*.

Dio rečenice…*potential for criminal action*… dobro je preveden u prijevodu 4a), dok u prijevodu 4b) bilježimo morfološki problem nepravilnoga dekliniranja i uporabe množine umjesto jednine koja je korištena u izvorniku, a potonji se problem bilježi i u prijevodu 4c). Sličan morfološki propust bilježimo i u dijelu ..*according to court records*…koje nijedan alat nije pravilno deklinirao.

Tablica 6.5. Primjer prevedene rečenice broj 5.

(5) The evaluation of successful staircase detection is made by using different input resolutions.	
GOOGLE TRANSLATE 5a)	Evaluacija uspješnog otkrivanja stubišta izrađena je korištenjem različitih rezolucija ulaza.

BING TRANSLATOR 5b)	Procjena uspješnog stubište otkrivanje je napravio pomoću različitih ulaznih razlučivosti.
YANDEX TRANSLATE 5c)	Rezultat uspješnog otkrivanja stepenice ostvariti s različitim rezolucijama unosa.

Imenica *evaluation* može se prevesti kao *evaluacija* ili *procjena*, što je učinjeno u prijevodima 5a) i 5b), dok je u prijevodu 5c) korištena imenica *rezultat* čijom je uporabom promijenjeno značenje. Nadalje, u prijevodu 5c) bilježimo nepravilno dekliniranje imenice *stepenice*, odnosno pogrešnu uporabu jednine umjesto množine, dok u prijevodu 5b) bilježimo i sintaktičku pogrešku slaganja riječi u rečenici. Za razliku od rečenice u prijevodu 5a) koja je sintaktički korektna, u prijevodu 5b) koristi se prošlo glagolsko vrijeme s naznakom vršitelja radnje u muškome rodu, a u prijevodu 5c) koristi se bezlična struktura infinitiva umjesto trpnoga stanja pasiva. Posljednje, *input resolutions* treba se prevesti s *ulaznim rezolucijama*, što je učinio alat Bing, dok su preostala dva alata zamijenile poredak pridjeva *input* i imenice *resolutions*. Iako se riječ *input* može prevesti riječju *ulaz*, u ovome je kontekstu prikladnija uporaba riječi *unos*, što nije korišteno u prijevodu 5a) iako bismo taj prijevod ocijenili kao najbolji.

Tablica 6.6. Primjer prevedene rečenice broj 6.

(6) When you get there, you retrieve a dude, bring him to 2015, and then walk him around and watch him react to everything.	
GOOGLE TRANSLATE 6a)	Kad dođete, dohvatite dude, dovedite ga do 2015. godine, a zatim

	ga prošetajte i gledajte ga da reagira na sve.
BING TRANSLATOR 6b)	Kada se tamo, dohvaćanje muško, dovesti ga do 2015., i onda neka hoda i paziti na njega reagiraju na sve.
YANDEX TRANSLATE 6c)	Kada dođete tamo, dobijete dude, dovesti ga do 2015. godine, a zatim ga prođe oko sebe i vidjeti kako reagira na sve.

When you get there najtočnije je preveo alat Yandex. Međutim, iako je priložna oznaka mjesta *there* (tamo) izostavljena u prijevodu 6a), značenje nije dvosmisleno jer se može iščitati iz prethodne rečenice. U prijevodu 6b) koristi se riječ *se* za koju ne znamo radi li se o pogrešnoj uporabi riječi ili je zatipak.

Prototipno je značenje glagola *to retrieve* dohvatiti nešto; međutim, u ovome kontekstu treba se koristiti glagol *pronaći*, što nijedan alat za strojno prevođenje nije učinio. Ovaj primjer ponovo ukazuje na programerski propust u kodiranju i ograničenom predviđanju prijevoda pojedine riječi koji će odgovarati različitim kontekstima. Imenica *dude* je kolokvijalni izraz za mušku osobu, a u hrvatskom jeziku najbolje odgovara imenici *tip*. Iako morfološki pogrešno zbog izostanka deklinacije pridjeva *muško* i/ili izostanka imenice *osoba* koju bi pridjev *muško* opisao, prijevod 6b) najbliže je prenio značenje imenice *dude*, dok su alati Google u 6a) i Yandex u 6b) ostavili imenicu u izvornome obliku. S obzirom da imenica *dude* postoji u hrvatskome jeziku i neformalni je izraz za *ženske grudi*, izostankom prijevoda, odnosno ostavljanjem imenice u izvornome obliku potpuno se mijenja značenje toga dijela rečenice. Drugim riječima, osim što nisu točni, prijevodi 6a) i 6c) čitatelja navode na pogrešan zaključak jer sugeriraju da, umjesto da se pronađe (dohvati) muška osoba, dohvate se ženske grudi.

Dio …*bring him to 2015*… treba se prevesti kao …*dovedite ga u 2015*… Nijedan alat za strojno prevođenje nije pravilno preveo prijedlog *to*, odnosno svi su se alati koristili opcijom doslovnoga prijevoda. Nadalje, neodređeni glagolski oblik infinitiv i zapovjedni glagolski

način imperativ strukturno su isti u engleskome jeziku. Za razlikovanje spomenutih, ključan je kontekst uporabe. Jedino se u prijevodu 6a) vodilo računa o kontekstu i pravilno se koristio imperativni glagolski način, dok se u prijevodima 6b) i 6c) upotrijebio infinitiv glagola.
…*walk him around*… može se prevesti kao u prijevodu 6a) *ga prošetajte* iako bi prikladnije bilo *prošetati s nekim*, a ne *nekoga* budući da se radi o osobi, a ne ljubimcu, stoga je prikladniji instrumental društva. Iako nije stilistički najbolji odabir, prijevod *neka hoda* iz 6b) jest razumljiv, dok je prijevod *ga prođe oko sebe* iz 6c) potpuno neshvatljiv. Posljednji dio rečenice …*watch him react to everything* prevodi se s …*gledajte ga kako reagira na sve* čemu je najbliži bio Google alat u 6a) ...*gledajte ga da reagira na sve*, dok je u prijevodu 6c) …*vidjeti kako reagira na sve* pogrešan odabir glagola *vidjeti* kao i njegov infinitivni oblik, no prijevod je shvatljiv. Glagol je *watch* višeznačan, stoga treba uključiti kontekst tijekom prevođenja. Jedan je od prijevoda spomenutoga glagola i *paziti*, no nikako ne odgovara danome kontekstu rečenice tako da je leksički pogrešan izbor glagola u prijevodu 6c). Također, glagol *reagirati* upotrijebljen je u pogrešnome obliku, a i prekršeno je pravilo o sročnosti između imenice u jednini i glagola u množini u istome primjeru.

Tablica 6.7. Primjer prevedene rečenice broj 7.

(7) The legal maneuver adds even more intrigue to the high-profile fight between two of the technology industry's largest companies, which are squaring off in the race to put driverless cars on the road.	
GOOGLE TRANSLATE 7a)	Pravni manevar još više ulijeva intrigu na borbu visokih profila između dviju najvećih tvrtki u tehnološkoj industriji, koje se kvare u utrci za stavljanje automobila bez vozača na cestu.
BING TRANSLATOR 7b)	Pravni manevar dodaje još više intriga visoka borba između dva tehnologija industrija najvećih kompanija, koje se natječu se u utrci

	staviti Svjetlopropusni automobila na cesti.
YANDEX TRANSLATE 7c)	Pravni manevar dodaje još više intriga u glasnijem borba između dva od najvećih kompanija u industriji visoke tehnologije, koje se protive u utrci staviti vozača automobila na cesti.

Fraza …*adds more intrigue*… pokazala se problematičnom za sva tri alata za strojno prevođenje, a posebice za Google. Naime, dok su se Bing i Yandex poslužili tehnikom doslovnoga prijevoda glagola *adds* u *dodaje*, Google se odlučio za drugačiji leksički odabir glagola *ulijeva*. Nije nam poznat razlog i ne vidimo motivaciju programera da se glagol *add* prevede s *ulijevati*. Osim što je pogrešan leksički odabir, glagol *ulijevati* ni stilistički ne odgovara imenici *intriga* jer se podrazumijeva da se ulijeva nešto što je tekuće, a intriga to definitivno nije. Može se, dakako, glagol *ulijevati* koristiti i u prenesenom značenju u frazama poput *ulijevati nadu,* no s imenicom *intriga* to nije slučaj. U ovome je slučaju bolji prijevod glagol *dodavati* koji su predložili alati Bing i Yandex iako bi najbolji prijevod bio glagol *stvarati*, što bi vjerojatno predložio ljudski prevoditelj. Nadalje, Google je prijedlog *to* doslovno preveo prijedlogom *na,* a Yandex prijedlogom *u* od kojih nijedan morfološki ne korespondira s ostatkom rečenice. Drugim riječima, prikladniji bi bio prijedlog *za* …*stvara intrigu za borbu*…

Nadalje, fraza …*high-profile fight*… mogla bi se prevesti s …*borba visokog profila*…, što je jedino Google dobro učinio. Kod prijevoda alata Bing nailazimo na morfološki problem jer je izostala deklinacija pridjeva *visoka* i imenice *borba*, a izostavljena je i imenica *profil*. Prijevod koji je ponudio alat Bing *visoka borba* ništa ne govori čitatelju i može se smatrati vrlo neuspjelim pokušajem prenošenja značenja fraze. I kod alata Yandex nailazimo na isti morfološki problem potpunoga izostavljanja deklinacije pa umjesto …*u glasnijoj borbi*… dobivamo …u *glasnijem borba*… Osim toga, s obzirom na korištenje imenice *borba* umjesto *profil,* prikladnija bi bila uporaba pridjeva *žešći* ili *snažniji* umjesto *glasniji* jer stilistički više odgovara odabranoj imenici. Dakle, osim poznavanja značenja riječi u izvornom i ciljnom

jeziku, neophodno je poznavati i stilistička pravila kako bi se mogao načiniti prikladan odabir riječi.

Nadalje, dio rečenice …*between two of the technology industry's largest companies*… stvorio je brojne probleme Bingu i Yandexu, dok ga je Google dobro preveo. Borba se odvija između dviju najvećih tvrtki tehnološke industrije, no sintaktički pored riječi u rečenici u izvornom i ciljnom jeziku nije jednak, što stvara problem alatima za strojno prevođenje. Kod alata Bing bilježimo uporabu tehnike doslovnoga prijevoda i sintaktički poredak kao u izvornome jeziku, što u najboljem slučaju otežava razumijevanje rečenice. Naime, korištenjem istoga poretka riječi kao u izvornome jeziku, mijenja se značenje toga dijela rečenice gdje se umjesto borbe dviju najvećih tvrtki u tehnološkoj industriji prenosi da se bore dvije najveće tehnologije iako ne znamo koje su one. Čak i uz neizostavnu intervenciju nakon strojnoga prijevoda, upitno je bi li čitatelj shvatio smisao toga dijela rečenice. Alat Yandex bolje je preveo problematični dio iako se neopravdano upotrijebio pridjev *visok*. Osim što se čitatelju ne objašnjava značenje visoke tehnologije, uporabom pridjev *visok* moguća je promjena značenja jer se u izvornome tekstu ne spominje da je djelokrug rada dviju tvrtki visoka tehnologija štogod ona predstavljala. Također, u spomenutome dijelu rečenice nailazimo i na gramatički, odnosno morfološki propust izostanka deklinacije broja *dva* (dviju) i nesročnost u vidu uporabe broja *dva* u muškome, a imenice *tvrtki*, na koju se broj odnosi, u ženskome rodu.

U dijelu rečenice …*which are squaring off in the race*… spomenute se tvrtke natječu u utrci, što je dobro prevedeno u prijevodu 7b), dok leksički pogrešnim odabirom glagola *kvariti* u 7a) i *protiviti* u 7c) potpuno se mijenja značenje rečenice. Naime, *kvariti u utrci* osim što sintagmatski ne odgovara, govorniku hrvatskoga jezika apsolutno ništa ne znači. Za razliku od toga primjera, prijevod iz 7c) *protiviti utrci* razumljiv je govorniku hrvatskoga jezika, no ima dijametralno suprotno značenje izvornome značenje *natjecati se u utrci*.

Posljednji dio rečenice …*to put driverless cars on the road* najbolje je preveo Google u 7a) s tim da je glagolske imenice stavljanje trebalo koristiti izvedeni oblik prefiksom po- *postavljanje*. Slično bilježimo i u prijevodima 7b) i 7c) s tim da se u tim primjerima umjesto neodređenoga glagolskoga oblika infinitiva *staviti* trebalo koristiti glagolsku imenicu *postavljanje*. Nadalje, sintagma *driverless car* već se prokazala problematičnom za prijevod u primjeru 1) gdje je alat Bing u 1b) upotrijebio riječ *Svjetlopropusni* umjesto *samovozeći automobil*. Dosljednost je zadržao i u prijevodu 7b). Iako stilistički nezgrapno, alat Yandex je u prijevodu 1c) prenio značenje, dok je u prijevodu 7c) posve pogrešno prenio značenje

izraza, odnosno umjesto postavljanja samovozećega automobila na cestu postavlja se vozač automobila na cestu. Posljednja, iako semantički nevažna, pogreška je nepravilna deklinacija imenice *cesta* u 7b) i 7c).

Tablica 6.8. Primjer prevedene rečenice broj 8.

(8) Nowadays, we are witnessing an increased availability of high resolution video and image capturing devices.	
GOOGLE TRANSLATE 8a)	Danas smo svjedoci povećane dostupnosti uređaja za snimanje videozapisa i slika visoke rezolucije.
BING TRANSLATOR 8b)	Danas, svjedoci smo povećane dostupnosti visoka rezolucija video i predodžba hvatanje uređaji.
YANDEX TRANSLATE 8c)	U današnje vrijeme smo svjedoci povećana dostupnost video visoke rezolucije i uređaj za snimanje slike.

Alat Google u 8a) najbolje je preveo zadanu rečenicu. Jedina je pogreška u krivom poretku riječi u rečenici kao i u prijevodu 8c) gdje su *visoke rezolucije* trebale ići iza riječi *uređaja* pa bi u ispravan prijevod rečenice glasio *Danas smo svjedoci povećane dostupnosti uređaja visoke rezolucije za snimanje videozapisa i slika.* Međutim, u prijevodu 8c) imenica *uređaji* trebala je ići je imenice *dostupnost* jer se odnosi i na video i na slike. Za razliku od prijevoda 8a) i 8c), alat Bing u 8b) poslužio se tehnikom doslovnoga prijevoda riječ po riječ *…visoka rezolucija video…* Iako prijevod ne utječe na razumijevanje, sintaktički je netočan.

Nadalje, imenica *image* u prirodnoj je kolokaciji s glagolom *capture*, a značenje je *zabilježiti/snimiti sliku*. Međutim, značenje glagola *capture* je i *uhvatiti nekoga,* odnosno *lišiti*

nekoga slobode. Prijevod 8b) ukazuje nam na programerski propust u predviđanju više značenja spomenutoga glagola, a samim time i programiranja rječnika koji ne obuhvaća sva značenja. Također, isti propust vidimo i kod uporabe imenice *image* koja može značiti *predodžba*, no u ovome se slučaju radi o imenici *slika,* odnosno programeri nisu uzeli u obzir kontekst mogućih uporaba spomenute imenice.

Ponovo bilježimo problem na morfološkoj razini u prijevodu 8c). Pridjev *povećana* i imenica *dostupnost* nisu pravilno deklarirani, odnosno upotrijebljeni su u nominativnome umjesto u genitivnome obliku. S obzirom na veliku razliku između engleskoga i hrvatskoga jezika u morfološkome smislu, budući da u engleskome jeziku nema deklinacije promjenjivih vrsta riječi, ovakve su pogreške očekivane. Doduše, s obzirom da je ova pogreška izostala u prijevodima 8a) i 8b), možemo zaključiti da su programeri Googlea i Binga odradili bolji posao barem što se tiče ovoga primjera.

Tablica 6.9. Primjer prevedene rečenice broj 9.

(9) This experience for him wouldn't be surprising or shocking or even mind-blowing—those words aren't big enough.	
GOOGLE TRANSLATE 9a)	Ovo iskustvo za njega ne bi bilo iznenađujuće ili šokantno ili čak i umom - te riječi nisu dovoljno velike.
BING TRANSLATOR 9b)	Ovo iskustvo za njega ne bi bilo iznenađujuće ili šokantan ili čak um puše — te riječi nisu dovoljno veliki.
YANDEX TRANSLATE 9c)	To iskustvo je za njega neće biti strašan, ili je šokantna ili čak взрывает mozak—te riječi nisu dovoljno velike.

U prijevodu rečenice 9) svi alati za strojno prevođenje imaju nekoliko istih grešaka. Prva se greška nalazi u dijelu rečenice *...mind blowing*... što bi u hrvatskom prijevodu bilo *šokantno,* a budući da je to već iskorišteno u prijevodu, ljudski bi se prevoditelj koristio tehnikom izostavljanja (u slučaju ovoga pridjeva). Međutim, nijedan alat za strojno prevođenje ne može razmišljati kao ljudski prevoditelj pa se nijedan nije poslužio gore spomenutom tehnikom. Dok u prijevodu 9b) bilježimo doslovan prijevod *um puše*, što nijednom govorniku hrvatskoga jezika ništa ne znači, u prijevodu 8a) imamo samo uporabu imenice *um,* a u prijevodu 9c) uporabu ćiriličnoga pisma koje govornici hrvatskoga jezika ne znaju čitati. Zanimljivo je za primijetiti da kada je god složeniji prijevod u pitanju, alat Yandex koristi ćirilično pismo kao i u prijevodima 1c) i 4c). Razlog zašto su programeri uopće ikada koristili ćirilicu ostaje nepoznat jer je službeno hrvatsko pismo latinica i govornici hrvatskoga jezika, posebno oni rođeni 1970-ih i kasnije, nikada nisu poučavani čitanju ćiriličnoga pisma.

Nadalje, u istome dijelu rečenice ponovo bilježimo morfološku pogrešku. U prijevodima 9b) i 9c) pridjev *šokantan* nije u kongruenciji s imenicom *iskustvo* koju opisuje, odnosno u prijevodu 9b) koristi se pridjev u muškom umjesto u srednjem rodu, dok se u prijevodu 9c) koristi pridjev u ženskom umjesto u srednjem rodu. Također, u prijevodu 9c), alat Yandex koristi nenaglašeni oblik pomoćnoga glagola *biti*, koji je nepotreban, kao i leksički pogrešnu uporabu pridjeva *strašan* umjesto *iznenađujući*. Pridjev *iznenađujući* znači da je nešto neočekivano, dok pridjev *strašan* ima negativne konotacije tako da se uporabom pridjeva *strašan* prenosi drugačiji učinak od onoga koji ima pridjev *iznenađujući*.

Posljednja se pogreška nalazi se u zadnjemu dijelu rečenice *...those words aren't big enough*... Svi su alati za strojno prevođenje to preveli kao *...te riječi nisu dovoljno velike/i...,* što je doslovan prijevod iz izvornika. Točan bi prijevod bi glasio *…to se iskustvo ne može opisati riječima*… Također, u prijevodu 9b) ponovo bilježimo slučaj nesročnosti, odnosno pridjev *veliki* koristi se u muškome rodu, a s obzirom da se odnosi na imenicu ženskoga roda *riječi*, trebao bi se upotrijebiti u ženskome rodu, što je učinjeno u prijevodima 9a) u 9c).

Tablica 6.10. Primjer prevedene rečenice broj 10.

(10) Waymo has accused Mr. Levandowski of stealing documents and poaching employees before quitting Google and then colluding with Uber to use that technology to advance driverless car efforts at the ride-hailing service.	
GOOGLE TRANSLATE 10a)	Waymo je optužio g. Levandowskog da je krao dokumente i krivolovao zaposlenike prije odustajanja od Googlea, a zatim se sudario s Uberom kako bi upotrijebio tu tehnologiju kako bi unaprijedio nastojanja automobila bez vožnje u usluzi vožnje.
BING TRANSLATOR 10b)	Waymo je optužio g. Levandowski krađa dokumenata i krade zaposlenika prije odvikavanje od Google i onda suraduje sa Uber koristiti tu tehnologiju unaprijed Svjetlopropusni auto napore na vožnju Pozdravljajući usluga.
YANDEX TRANSLATE 10c)	Waymo optužio g na Левандовского u krađi dokumenata i переманивание osoblja prije odlaska Google, a zatim u dosluhu s uber koristiti ovu tehnologiju za promociju bespilotnih napore automobil voziti-grad uslugu.

U brojnim smo prethodnim primjerima pokazali da se morfološke razlike između engleskoga i hrvatskoga jezika najčešće realiziraju prilikom deklinacije promjenjivih vrsta riječi. Za razliku od engleskoga jezika, u hrvatskome se jeziku promjenjive vrste riječi dekliniraju. Iako ne utječe na značenje ili razumijevanje rečenice, izostanak deklinacije i uporaba promjenjive vrste riječi u njenome izvornome obliku netočna je. Primjer izostanka deklinacije vlastitoga imena *Levanowski* imamo u prijevodima 10b) i 10c). U prijevodu 10b) *Waymo je optužio g. Levandowski*, vlastito je ime (točnije prezime) upotrijebljeno u nominativnome umjesto u akuzativnome obliku *Levandowskoga*. Ovakvi primjeri ukazuju na potrebu da se u unutarnji riječi alata za strojno prevođenje unesu svi deklinacijski oblici promjenjivih vrsta riječi. Kod

alata Yandex u prijevodu 10c) već standardno nailazimo na uporabu ćiriličnoga pisma *Левандовского* nečitljivoga govornicima hrvatskoga jezika. Osim izostanka deklinacije vlastitoga imena, u spomenutome primjeru bilježimo i izostanak uporabe nenaglašenoga oblika pomoćnoga glagola *biti* u prijevodu 10c) *Waymo optužio* i nepotrebno dodavanje prijedloga *na*, što je tipičnije za neke druge južnoslavenske jezike.

Glagol *optužiti* u hrvatskome jeziku korelira s prijedlogom *za* (optužiti nekoga za nešto) pa je nastavak rečenice trebao glasiti *...za krađu dokumenata*…, što nije alat nije ponudio. U prijevodu 10b) bilježimo uporabu imenice *krađa* u nominativnome obliku, do je u prijevodu 10c) pogrešna uporaba prijedloga *u* u skladu s kojim je, doduše, imenica *krađa* deklinirana.

Prototipno je značenje glagola *to poach* na hrvatskome *krivolovati*. Međutim, glagol *krivolovati* u hrvatskome se jeziku koristi za neovlašteni lov životinja. S obzirom da ovdje to nije slučaj, uporaba glagola *krivolovati* leksički je potpuno pogrešna. S obzirom na kontekst rečenice, glagol *to poach* trebao se prevesti kao *vrbovati*, što nije učinjeno ni u jednom prijevodu. Osim pogrešnoga prijevoda glagola, u prijevodu 10b) imenica *zaposlenici* upotrjebljena je u jednini umjesto u množini, čime se mijenja značenje rečenice jer se dobivao dojam da se vrbovao jedan posebni zaposlenik, a ne skupina njih. U prijevodu 10c) ponovo bilježimo uporabu ćiriličnoga pisma *переманиване* i potpuno nerazumijevanje toga dijela rečenice.

Nadalje, jedan od prijevoda glagola *to quit* jest *odvikavanje*; međutim, u ovome kontekstu trebalo je upotrijebiti *prije napuštanja/prije nego je dao otkaz* jer se radi o tome da je Levandowski vrbovao zaposlenike prije negoli je dao otkaz u Googleu. Iako netočan, prijevod 10a) vjerojatno bi bio dobro shvaćen, dok prijevod 10b) navodi na zaključak da je subjekt razvio ovisnost o Googleu, što nikako nije točno. Također, izostanak prijedloga u prijevodu 10c) dovodi do dvostrukoga značenja budući da će si govornik hrvatskoga jezika samoinicijativno dodati jedan od dvaju mogućih prijedloga u taj dio rečenice. Ako doda prijedlog *iz*, dobiva se …*prije odlaska iz Googlea*…, što je pravo značenje rečenice, no ako doda prijedlog *u*, dobiva se …*prije odlaska u Google*…, što znači da subjekt odlazi raditi u, a ne iz Googlea i potpuno se mijenja značenje. Iako naizgled kratka i nevažna riječ, prijedlog također može uvelike utjecati na značenje rečenice i njihovoj uporabi treba pristupiti s oprezom.

Glagol *to collude* znači *biti u trajnom sporazumu,* a *to collide sudariti*. Ovdje se vjerojatno radi o programerski pogrešno unesenom prijevodu riječi što mijenja značenje rečenice u 10a),

dok se u prijevodima 10b) i 10c) značenje može razaznati. Kao i na početku prijevoda 10b) i 10c), ponovo bilježimo izostanak deklinacije vlastitoga imena Uber kod istih alata, dok kod alat Yandex u 10c) bilježimo i uporabu vlastitoga imena malim slovom.

Nadalje, dio …*to use that technology to advance*… trebao bi se prevesti s …*kako bi upotrijebio tu tehnologiju kako bi unaprijedio*…, što je dobro učinjeno u prijevodu 10a). Umjesto uporabe kondicionala prvoga *kako bi upotrijebio/koristio,* u prijevodima 10b) i 10c) bilježimo uporabu neodređenoga glagolskoga oblika infinitiva *koristiti*, što je zapravo doslovan prijevod strukture iz izvornoga jezika. Također, umjesto uporabe kondicionala prvoga *kako bi unaprijedio,* u prijevodu 10b) bilježimo uporabu pogrešnoga izvedenoga oblika riječi, odnosno imenicu *naprijed*, dok se u prijevodu 10c) koristi druga riječ *promocija* čije značenje ne odgovara kontekstu izvorne rečenice. Naime, *unaprijediti nešto* znači sudjelovati u procesu izrađivanja, dok *promovirati nešto* znači sudjelovati nakon što je proces izrađivanja dovršen.

Sintagma *driverless car* već se pokazala problematičnom u primjerima 1) i 7), a i ovdje je to slučaj kod svih triju alata. *Automobil bez vožnje* iz prijevoda 10a) ukazivao bi na to da je automobil tek izrađen i nije imao priliku još biti vožen. Alat Bing dosljedno navedenu sintagmu prevodi sa *Svjetlopropusni automobil,* dok se u prijevodu 10c) pojavljuje pridjev *bespilotni*, a opće je poznato da samo vozila u zračnome prometu mogu biti opisana pridjevom *bespilotni*. Drugim riječima, takvo opće ili značenje o svijetu može imati samo ljudski prevoditelj. Imenicu *efforts*, koja je u izvornom jeziku korištena zajedno s navedenom sintagmom *driverless car,* ljudski bi prevoditelj potpuno izostavio iz prijevoda, dok su ju sva tri alata prevela tehnikom doslovnoga prijevoda.

Posljednji dio rečenice …*at the ride-hailing service* mogao bi se prevesti kao u prijevodu 10a) …*u usluzi vožnje*. Evidentno je načinjen pogreška na leksičkoj razini i u prijevodu 10b) ...*vožnju Pozdravljajući usluga* i 10c) …*voziti-grad uslugu*. Niti u jednome od dvaju spomenutih prijevoda ne možemo dokučiti motivaciju za takav prijevod budući da se ne radi o doslovnome prijevodu riječ po riječ niti o nekoj drugoj učestaloj prevoditeljskoj metodi. S tim u svezi, taj je dio rečenice i u prijevodu 10b) i 10c) potpuno nerazumljiv čitatelju.

Tablica 6.11. Primjer prevedene rečenice broj 11.

(11) Evaluation is made on the method for staircase detection which is tailored for use in assistance systems for the blind and visually impaired.	
GOOGLE TRANSLATE 11a)	Procjenjuje se metoda za otkrivanje stubišta koja je prilagođena za uporabu u sustavima pomoći slijepim i slabovidnim.
BING TRANSLATOR 11b)	Obavlja na način za otkrivanje stubišta koji je prilagođen za uporabu u sustavima pomoći za slijepe i slabovidne osobe.
YANDEX TRANSLATE 11c)	Procjena se vrši na temelju metoda za otkrivanje stubište, koji je dizajniran za korištenje u sustavima skrbi za slijepe i slabovidne.

Ovo je jedna od najbolje prevedenih rečenica za sva tri strojna prevoditelja te nema puno grešaka. Preciznije, prijevod u 11a) potpuno odgovara izvorniku. Jedina pogreška u prijevodu 11b) jest leksički pogrešan odabir glagola *obavljati* umjesto glagola *procjenjivati* ili *vrednovati*. Nadalje, u izvorniku je upotrjebljeno trpno stanje pasiv i isto se moglo/trebalo upotrijebiti u prijevodu. Drugim riječima, u prijevodu 11b) nedostaje čestica *se* iza glagola.
Imenicu *method* alati su preveli kao *metoda* u 11a) i 11c) ili *način* u 11b). Obje su riječi adekvatan prijevod imenice iz izvornika. Međutim, u prijevodu 11c) bilježimo uporabu množine umjesto jednine, što svakako utječe na značenje rečenice. Nastavno na prethodno, odnosna zamjenica *which* (koji/koja/koje) odnosi se na imenicu *metoda* i treba s njome biti u kongruenciji, što je slučaj u prijevodu 11a) i 11c). Drugim riječima, u prijevodu 11b) umjesto zamjenice u ženskome rodu *koja* upotrjebljena je zamjenica *koji* u muškome rodu.
Iako ne utječe na značenje rečenice, sintagma *blind and visually-impaired* u hrvatskome se jeziku prevodi sa *slijepe i slabovidne osobe,* odnosno dodaje se imenica osobe iako ista nije

korištena u izvorniku. Za razliku od prijevoda 11b), spomenuta imenica nije korištena u prijevodima 11a) i 11c).

Tablica 6.12. Primjer prevedene rečenice broj 12.

(12) But here's the interesting thing—if he then went back to 1750 and got jealous that we got to see his reaction and decided he wanted to try the same thing, he'd take the time machine and go back the same distance, get someone from around the year 1500, bring him to 1750, and show him everything.	
GOOGLE TRANSLATE 12a)	Ali ovdje je zanimljiva stvar - ako se vratio natrag do 1750. godine i postao ljubomoran kad smo vidjeli njegovu reakciju i odlučili je pokušati ista stvar, preuzeti vremenski stroj i vratiti se na istu udaljenost, dobiti nekoga iz Oko 1500. godine, dovesti ga do 1750. i pokazati mu sve.
BING TRANSLATOR 12b)	Ali ovdje je zanimljiva stvar, ako je onda se vratio u 1750 i ljubomoran da smo vidjeli njegovu reakciju i odlučio da će pokušati isto, bi se vremeplov i vratiti ista udaljenost, dobiti netko od oko 1500 godina, dovesti ga do 1750, te mu sve pokazati.
YANDEX TRANSLATE 12c)	Ali to je velika stvar—ako se vratio na 1750 і приревновал da smo stigli, da vidi njegove reakcije, i on je odlučio pokušati isto, da bi se vremenski stroj i vratiti se na istu udaljenost, uzeti nekoga od oko 1500, dovesti ga do 1750, i pokazati mu sve.

Tehniku doslovnoga prijevoda bilježimo u prijevodima 12a) i 12b) odmah na početku rečenice. *But here's the interesting thing...* prevelo se s *Ali ovdje je zanimljiva stvar...* Priložna oznaka mjesta *here* nije u službi ukazivanja na mjesto radnje, stoga se ne bi ni trebala prevesti s *ovdje*. Alat za strojno prevođenje, dakako, teško može prepoznati stilističke finese i prijevod prilagoditi kako bi postigao isti učinak ne iskoristivši iste riječi iz izvornoga jezika, dok je to upravo ono što ljudski prevoditelj radi. Ovu bi rečenicu ljudski prevoditelj preveo s *Ali evo jedne zanimljive stvari...*, dakle, uopće ne bi koristio priložnu oznaku mjesta. Dok u prijevodima 12a) i 12b) nije došlo do promjene na semantičkoj razini, u prijevodu 12c) uporabom pridjeva *velik* umjesto *zanimljiv* utječe se na značenje rečenice jer nešto što je zanimljivo, ne znači da je i veliko.

U daljnjem dijelu rečenice koristi se nestvarni pogodbeni način drugi kondicional, čija je i struktura i uporaba različita od pogodbenoga načina kondicionala drugoga u hrvatskome jeziku. Dok se u engleskome jeziku koristi prošlo svršeno glagolsko vrijeme *Past Simple*, u hrvatskome bi s jeziku trebalo koristiti sadašnje glagolsko vrijeme *prezent*. Drugim riječima, umjesto *se vratio*, treba se koristiti *se vrati*. Osim pogreške u uporabi glagolskoga vremena, u prijevodu 12b) bilježimo i bespotrebnu uporabu nenaglašenoga oblika pomoćnoga glagola *biti*.

Nadalje, ispred 1750. godine treba ići prijedlog *u* koji se, kao takav, nalazi samo u prijevodu 12b), dok se u drugim dvama prijevodima koriste prijedlozi *do* i *na*, čija je uporaba rezultat korištenja tehnike doslovnoga prevođenja. Za razliku od engleskoga jezika u kojemu se ne koristi interpunkcijski znak točka iza brojeva, u hrvatskome se jeziku koristi iza rednih brojeva. Stoga, u prijevodima 12b) i 12c) bilježimo pravopisnu pogrešku zbog neuporabe interpunkcijskoga znaka točke iz rednoga broja 1750. Budući da se u hrvatskome jeziku interpunkcijski znak točka ne koristi iza glavnih brojeva, neuporaba iste iza rednih brojeva može dovesti do nejasnoga ili pogrešnoga značenja.

Logičan nastavak pogrešne uporabe glagolskoga vremena bilježimo u dijelu …*i postao ljubomoran*…, dakle, umjesto prošloga, treba se koristiti sadašnje glagolsko vrijeme …*i postane ljubomoran*… Iako pogrešno glagolsko vrijeme, u prijevodu 12a) barem se koristi glagol; u prijevodu 12b) glagol je potpuno izostavljen, dok je u prijevodu 12c) upotrijebljeno ćirilično pismo nečitljivo govornicima hrvatskoga jezika i latiničnoga pisma. Nadalje, iza pridjeva *ljubomoran* najprikladnije je koristiti uzročni veznik *jer/zato što* koji je u prijevodu pogrešno zamijenjen priložnom oznakom vremena *kad* u prijevodu 12a) i česticom da u

prijevodima 12b) i 12c). Nadalje, ponovo se upotrjebljava pogrešno glagolsko vrijeme u prijevodu 12a) i nesročnost s ostalim glagolima u rečenici pa umjesto i …*odluči pokušati*... dobivamo …*i odlučili je pokušati*… Po prvi puta bilježimo uporabu kolokvijalnoga dakanja u prijevodu 12b) …*odlučio da će pokušati*… koje je tipično za srpski, no ne i za hrvatski jezik.
Nadalje, osim pogrešnoga glagolskoga vremena i oblika riječi *uzeo bi*, u prijevodu 12a) bilježimo uporabu glagola *preuzeti*; međutim, iako morfološki pogrešno, u prijevodu 12a) koristi se glagol, dok on potpuno izostaje u prijevodima 12b) …*bi se vremeplov*… i 12c) …*bi se vremenski stroj*…, što je vrlo problematično za razumijevanje rečenice jer čitatelj ne saznaje što se događa s vremenskim strojem zbog izostavljanja ključnoga glagola. Ovaj primjer ukazuje na važnost prijevoda riječi koje nose temeljno značenje rečenice.
U prethodnom smo dijelu analize primjera 12) ukazali na važnost pravilne uporabe interpunkcijskih znakova, a sljedeći dio rečenice potvrđuje naše tvrdnje. Naime, dio …*get someone from around the year 1500*… treba se prevesti kao …*naiđite nekoga iz oko 1500. godine (tisuću petstote godine)*... Pravopisno ispravnu uporabu interpunkcijskoga znaka točke bilježimo jedino u prijevodu 12a). Međutim, ovaj primjer ne ukazuje samo na pravopisnu pogrešku, nego na pravopisnu pogrešku izostavljanja interpunkcijskoga znaka koji utječe na značenje rečenice budući da se u prijevodima 12b) …*dobiti netko od oko 1500 godina*… i 12c) …*uzeti nekoga od oko 1500*… sugerira da se pronađe osoba koja ima 1500 (tisuću petsto) godina, a ne koja je živjela 1500. (tisuću petstote) godine. Pored ove pogreške, neopravdana uporaba velikoga slova u riječi *oko* u 12a), izostanak deklinacije neodređene zamjenice *netko* u 12b) ili doslovan prijevoda glagola *get* u *dobiti* umjesto *pronaći* u sva tri prijevoda čine se zanemarivima jer ne utječu na semantiku rečenice.

Tablica 6.13. Primjer prevedene rečenice broj 13.

(13) As part of the motion seeking the injunction, Waymo said that Mr. Levandowski, while still working at Google, installed software that allowed him to download over 14,000 files, or about 9.7 gigabytes of data, pertaining to the driverless car program.

GOOGLE TRANSLATE 13a)	U sklopu prijedloga koji traži sudsku zabranu, Waymo je rekao da je g. Levandowski, dok je još radio na Googleu, instaliran softver koji mu je omogućio preuzimanje preko 14.000 datoteka, odnosno oko 9,7 gigabajta podataka, koji se odnose na automobilski program vozača.
BING TRANSLATOR 13b)	Kao dio pokreta koji traže zabranu, Waymo je rekao da g. Levandowski, dok je još radio u Google, instaliran softver koji ga to preuzimanje datoteka više od 14.000 datoteke ili oko 9.7 gigabajta podataka, koji se odnose na Svjetlopropusni auto program.
YANDEX TRANSLATE 13c)	U okviru zahtjev za zabranu, rekao je Waymo da g Левандовского, još uvijek radim u Google, softver, što mu je omogućilo preuzimanje više od 14.000 datoteka, ili oko 9,7 gigabajta podataka koji se odnose na programu vozača automobila.

Morfološke pogreške potpunoga izostanka i nepravilne deklinacije promjenjivih vrsta riječi vrlo su česte u svim analiziranim primjerima, a ni primjer 13) nije izuzetak. Za razliku od prijevoda 13a) *U sklopu prijedloga*… i 13b) *Kao dio pokreta*…, u prijevodu 13b) *U okviru zahtjev*… imenica *zahtjev* upotrijebljena je u nominativnome umjesto u genitivnome obliku. Sličan problem bilježimo i kod deklinacije vlastitoga imena *Google* u prijevodima 13b) i 13c) gdje se umjesto nominativnoga oblika …*u Google*… trebao upotrijebiti lokativni oblik …*u Googleu*…, što smo već zabilježili i u prijevodima 10b) i 10c). Osim izostanka deklinacije vlastitoga imena, kao i u prijevodima 4c) i 10c), u prijevodu 13c) bilježimo uporabu ćiriličnoga pisma *Левандовского*.

Nadalje, uporaba se prikladnoga glagolskoga vremena, makar to značilo korištenje različitih glagolskih vremena u izvornom i ciljnom jeziku, a sve u svrhu postizanja istoga učinka, pokazala ključnom u primjeru 12), a i ovdje je to slučaj. Dok se u prijevodima 13a) i 13b) upotrebljava prošlo glagolsko vrijeme …*dok je još radio*… čime se ukazuje na svršenost radnje, u prijevodu 13c) upotrebljava se sadašnje glagolsko vrijeme …*još uvijek radim*… čime se mijenja značenje rečenice. Do promjene glagolskoga vremena u 13c) vjerojatno je došlo zbog izostanka pomoćnoga glagola *to be* (was) u izvornome tekstu. Međutim, unatoč tome, iz konteksta se rečenice razaznaje vremenska dimenzija i ne bi se smjela dogoditi promjena iste. U istome dijelu rečenice, u prijevodu 13a), zbog uporabe prijedloga *na* umjesto prijedloga *u*, mijenja se značenje jer ispada da je subjekt radio na internetskoj stranici/tražilici Google (programiranje, održavanje i sl.), a ne da je bio zaposlen u tvrtki imena Google.

…while still working at Google… umetnuti je dio rečenice iza kojega se koristi riječ *installed*. S obzirom da je *installed* nužan nastavak dijela …*Waymo said that Mr. Levandowski*… riječ *installed* nije pridjev po vrsti riječi, nego glagol u prošlome glagolskome vremenu i trebalo ga je prevesti s *je instalirao*, a ne *instaliran*. Za razliku od ljudskoga prevoditelja koji može prepoznati umetnute dijelove rečenice i točno odrediti vrste riječi, a samim time i pravilno i prevesti, vidimo da to nije slučaj s alatima za strojno prevođenje. U prijevodima 13a) i 13b) pogrešno je korištena vrsta riječi, dok je uporaba iste posve izostala u prijevodu 13c) čime se utječe na značenje jer čitatelj ne dobiva informaciju što se radi sa softverom.

Posljednji dio rečenice …*driverless car program* nijedan alat za strojno prevođenje nije dobro preveo. Temeljna riječ koja nosi značenje toga izraza jest pridjev *driverless* odnosno *samovozeći* i zbog njena izostavljanja, u potpunosti je otežano razumijevanje rečenice. Također, u prijevodu 13b) ponovo se koristi pridjev *svjetlopropusni* koji nema nikakvo značenje u hrvatskome jeziku. Zanemarivši morfološke pogreške dekliniranja riječi kao u 13c) …*na programu*... umjesto …*na program*… i poredak riječi u rečenici u 13a) …*automobilski program vozača*… umjesto …*program samovozećega automobila*… ključna je pogreška izostavljanje pridjeva *samovozeći* koji nosi značenje cijele rečenice.

Tablica 6.14. Primjer prevedene rečenice broj 14.

(14) The main goal is to find the lowest resolution with acceptable detection accuracy using this method for staircase detection because lower resolutions significantly reduce execution time.	
GOOGLE TRANSLATE 14a)	Glavni je cilj pronaći najnižu razlučivost s prihvatljivom točnosti detekcije pomoću ove metode za otkrivanje stubišta jer niže rezolucije značajno smanjuju vrijeme izvršenja.
BING TRANSLATOR 14b)	Glavni cilj je pronaći najniže rezolucije s prihvatljivim otkrivanje točnost koristeći ovu metodu za otkrivanje stubište jer niže razlučivosti značajno smanjiti vrijeme izvršavanja.
YANDEX TRANSLATE 14c)	Glavni cilj-pronaći najniže rezolucije sa prihvatljivom preciznošću detekcije, koristeći ovu metodu za otkrivanje stepenice-za niske rezolucije, znatno će smanjiti vrijeme izvršavanja.

Prijevod 14a) u potpunosti je točan i može poslužiti kao ogledni primjer za usporedbu. U dijelu prijevoda *...najniže rezolucije...* imenica *rezolucije* i njezin superlativ *najniže* korištene su u množini umjesto u jednini, što, dakako, utječe na značenje. Izostanak deklinacije promjenjivih vrsta riječi bilježimo u prijevodu 14b) pa umjesto …*s prihvatljivim otkrivanjem točnosti*… dobivamo …*s prihvatljivim otkrivanje točnost*…, dakle umjesto uporabe genitiva, koristi se nominativni oblik. Istu pogrešku nalazimo u prijevodima 14b) …*za otkrivanje stubište*… i 14c) …*za otkrivanje stepenice*… gdje se ponovo koristi nominativni umjesto genitivnoga oblika imenice. Doduše, u prijevodu 14c) ne možemo znati je li riječ o pogrešnome dekliniranju imenice ili uporabi iste u jednine umjesto u množini, no u svakome je slučaju morfološka pogreška vidljiva.

Nadalje, uporabu morfološki pogrešnoga oblika glagola bilježimo u dijelu …*značajno smanjuju*… gdje se u prijevodu 14b) koristi neodređeni glagolski oblik infinitiv …*značajno smanjiti*..., a u prijevodu 14c) buduće glagolsko vrijeme …*znatno će smanjiti*… umjesto sadašnjega glagolskoga vremena. No, za razliku od sličnih prethodno analiziranih primjera, uporaba drugačijega oblika ili glagolskoga vremena u ovome slučaju ne utječe na razumijevanje ili značenje rečenice.

Po prvi puta bilježimo neopravdanu uporabu interpunkcijskoga znaka spojnice u prijevodu 14c) …*cilj-pronaći*... i ….*stepenice-za*… za čiju uporabu ne nalazimo suvislo objašnjenje budući da se navedeni interpunkcijski znak ne koristi u izvorniku.

Također, možemo spomenuti da su uočene dvije manje greške koje su više posao za lektore nego za alate za strojno prevođenje, a one su u prijevodu 14b) gdje umjesto *Glavni cilj je*… nenaglašeni oblik pomoćnoga glagola biti treba ići ispred imenice *cilj Glavni je cilj*… i u prijevodu 14c) treba se koristiti prijedlog *s*, a ne *sa*.

Tablica 6.15. Primjer prevedene rečenice broj 15.

(15) The 1500 guy would learn some mind-bending shit about space and physics, he'd be impressed with how committed Europe turned out to be with that new imperialism fad, and he'd have to do some major revisions of his world map conception.	
GOOGLE TRANSLATE 15a)	1500 čovjek bi naučio nešto o savijanju sile o prostoru i fizici, bio bi Impresioniran s koliko je Europa postala predodređenom tom novom imperijalizmu, i morat će napraviti neke velike izmjene svoje koncepcije karte svijeta.
BING TRANSLATOR 15b)	1500 tip bi naučiti sranje um-savijanje prostora i fizike, je impresioniran s naš Europe pokazala se sa taj novi imperijalizam hir i morao bi raditi neke velike izmjene začeću kartu svijeta.

YANDEX TRANSLATE 15c)	U 1500 momak htio naučiti neke halucinogena sranja o svemiru i fizici, on bi bio impresioniran kako je napredovao u Europi se ispostavilo da je s novog imperijalizma пунктик, i on mora napraviti neke velike promjene svoj svjetonazor karti.

U prijevodima 12b) i 12c) ukazali smo na važnost korištenja interpunkcijskoga znaka točke čije izostavljanje može utjecati na promjenu značenja rečenice. Sličan slučaj imamo u prijevodima primjera 15) na početku rečenice *The 1500 guy...* Iako je izostavljen interpunkcijski znak točke u prijevodu 15c) *U 1500 momak*…, čitatelj nedvojbeno razaznaje da se radi o muškoj osobi koja je živjela 1500. (tisuću petstote) godine, dok u prijevodima 15a) *1500 čovjek*… i 15b) *1500 tip*… čitatelj uopće ne može uočiti poveznicu između broja 1500 i imenice čovjek/tip, odnosno izvorno se značenje uopće ne prenosi prijevodima 15a) i 15b).

Nastavno na prethodno, dio …*would learn some mind-bending shit*… pokazao se problematičnim u svim trima prijevodima. Pridjev *mind-bending* sinonim je poznatijega pridjeva *mind-blowing* i označava nešto šokantno ili iznenađujuće. Iako pridjev *bending* inače označava nešto što se može savijati, kada se nalazi u kombinaciji s *mind,* pridjev u potpunosti mijenja svoje značenje. U prijevodu 15a) izostavljena je imenica *mind* iz prijevoda, dok se u prijevodu 15b) *um-savijanje* koristi tehnika doslovnoga prijevoda. Za razliku od spomenutih, u prijevodu 15c) koristi se pridjev *halucinogeni* čije je značenje potpuno neusporedivo sa značenje iz izvornika. Slično, u prijevodu 15a) upotrebljava se imenica *sila* čija bi uporaba mogla čitatelja zbuniti i time utjecati na razumijevanje rečenice. Vulgarizam *shit* prevodi se u prijevodima 15b) i 15c), dok se izostavlja u 15a). Izostavljanje ovoga vulgarizma ne utječe na značenje rečenice. Budući da je to pitanje prevoditeljske etike, bi li ga koristio ljudski prevoditelj ne možemo reći sa sigurnošću, no s obzirom na vrstu rada (popularno-znanstveni rad) i činjenicu da njegovo izostavljanje ne utječe na samo značenje, prevoditelj bi se vjerojatno odlučio izostaviti ga iz prijevoda.

Jedno je od značenja imenice *space prostor*, no uzimajući u obzir cjelokupan kontekst, odmah se zaključuje da se ne radi o prostoru, nego o svemiru tako da u prijevodima 15a) i 15b) imamo leksički pogrešan odabir riječi.

Najproblematičniji je dio rečenice …*he'd be impressed with how committed Europe turned out to be with that new imperialism fad*… Iako ne utječe na značenje, u prijevodu 15b) upotrebljava se prošlo svršeno glagolsko vrijeme *je impresioniran,* dok je u izvorniku i prijevodima 15a) i 15b) upotrjebljen pogodbeni glagolski način kondicional *bio bi impresioniran* s tim da u prijevodu 15a) bilježimo neosnovanu uporabu velikog početnog slova u riječi *impresioniran*. Pridjev *committed* znači *odan/vjeran*, što ni u jednome od triju prijevoda nije točno upotrjebljeno. Frazalni glagol *turn out* u ovome kontekstu znači *pokazati se/postati*, što je dobro upotrjebljeno u prijevodima 15a) i 15b), dok je u prijevodu 15c) upotrjebljen glagol *napredovati* kojim se mijenja značenje rečenice. Nadalje, imenica *fad* prevodi se s *hir/prohtjev*, što je dobro prevedeno u prijevodu 15b). Iako se sama imenica izostavlja u prijevodu 15a), to ne utječe na razumijevanje rečenice. Štoviše, postoji realna mogućnost da bi ju i ljudski prevoditelj izostavio iz prijevoda. Već tradicionalno, kada je god riječ o zahtjevnijem prijevod, alat za strojno prevođenje Yandex koristi ćirilično pismo, što bilježimo u prijevodu 15c) *пунктик.* Neizostavno je za spomenuti da u spomenutome dijelu rečenice bilježimo brojne pogreške na morfološkoj razini, odnosno izostavljanje potrebne deklinacije promjenjivih vrsta riječi kao u prijevodu 15b) *pokazala se sa taj novi imperijalizam hir* ili 15c) *ispostavilo da je s novog imperijalizma пунктик*. Iako je pridjev *committed* pogrešno preveden, prijevod spomenutoga dijela rečenice najuspješnije je preveden Google Translate alatom u 15a). Međutim, s obzirom na brojne poteškoće na morfološkoj, leksičkoj i semantičkoj razini, možemo zaključiti da je ovaj dio rečenice neuspješno preveden u prijevodima 15b) i 15c) i djelomično uspješno u prijevodu 15a).

Nadalje, slično kao i u jednom od prethodnih dijelova rečenice, u dijelu …*he'd have to do*… treba se upotrijebiti pogodbeni glagolski način kondicional *morao bi/trebao bi* kao što je prevedeno u 15b), a ne koristiti buduće glagolsko vrijeme *morat će* kao u 15a) ili sadašnje glagolsko vrijeme/imperativ *mora* kao u 15c).

I u posljednjemu dijelu rečenice …*his world map conception* nailazimo na probleme osim u prijevodu 15a) …*svoje koncepcije karte svijeta*. Imenica *conception* može značiti začeće nečega novoga (najčešće života), no isto tako može označavati viziju, koncepciju ili svjetonazor. S obzirom na kontekst rečenice, potonje je značenje riječi trebalo odabrati, što

nije učinjeno u prijevodu 15b), nego je upotrjebljena imenica *začeće*. Kao i u brojnim prethodnim primjerima, u prijevodima 15b) …*začeću kartu svijeta* umjesto …*u viziji karte svijeta* i 15c) …*svoj svjetonazor karti* umjesto …*na svojoj svjetonazorskoj karti* bilježimo izostanak prijedloga, a posljedično i deklinacije promjenjivih vrsta riječi.

7. ZAKLJUČAK

Nužan rezultat internacionalizacije i globalizacije jest potreba komuniciranja u širemu smislu. Iako se engleski jezik nametnuo kao *lingua franca*, ljudi se još uvijek osjećaju slobodnije i sigurnije koristeći svoj materinji jezik. Stoga i dalje postoji potreba za prevođenjem s izvornoga na ciljni jezik. Neupitno je da su školovani prevoditelji najbolji za prevođenje i tumačenje izvornoga jezika; međutim, zbog ubrzanoga načina života i kako bi se odgovorilo na sve veće zahtjeve za prevođenjem, kao nužan se odgovor nameće strojno prevođenje i uporaba različitih alata u tu svrhu. Iako kvaliteta strojno prevedenoga teksta možda nije na vrhunskoj razini te zahtijeva puno korekcija prevoditelja, daleko je lakše, brže i jeftinije ispraviti eventualne greške, nego prevoditi cijeli tekst „ručno".

Cilj je ovoga rada bio analizirati rad triju besplatnih alata za strojno prevođenje Google translate, Bing translator i Yandex translate. Korpus se istraživanja sastojao od nasumično odabranih triju tekstova različitih vrsta - izvorni znanstveni rad, popularno znanstveni rad i novinski članak. Tekstovi su izvorno napisani na engleskome jeziku, a koristeći se spomenutim alatima, strojno su prevedeni na hrvatski jezik. Nakon prijevoda, tekstovi su usporedno analizirani na morfološkoj, sintaktičkoj, semantičkoj i leksičkoj razini, a u svrhu je ovoga diplomskoga rada odabrano 15 rečenica.

Zabilježene su brojne pogreške na svim jezičnim razinama. S obzirom na razlikovanje dvaju jezičnih sustava, gdje u engleskome jeziku nema deklinacije promjenjivih vrsta riječi za razliku od hrvatskoga jezika, pogrešna deklinacija ili potpuni izostanak deklinacije promjenjivih vrsta riječi bio je očekivan. Problem dekliniranja zabilježen je i u uporabi općih imenica i vlastitih imena koja su u jednome slučaju čak neutralizirana i nepotrebno prevođena na hrvatski jezik. Također, zabilježena je uporaba pogrešnoga broja riječi (jednina umjesto množine i vice versa), što utječe na značenje rečenice. Nadalje, u brojnim je primjerima

prekršeno pravilo sročnosti, odnosno slaganja riječi u rodu, broju i padežu kao i uporaba pogrešnoga glagolskoga vremena ili oblika, čime se kompromitiralo značenje rečenice.

Jedan je od najvećih problema strojnoga prevođenja leksički pravilan odabir značenja višeznačnih riječi, što smo zabilježili u mnogim primjerima. Prilikom slaganja unutarnjega rječnika, mora doći do sinergije jezičara, koji će popisati sva moguća značenja određene riječi, i programera, koji će ih unijeti u unutarnji rječnik. Međutim, ni to nije jamstvo da se i dalje neće događati problem pogrešnoga odabira jer on ovisi o kontekstu, što alat za strojno prevođenje teško može uzeti u obzir. Sličan se problem javlja i kod prijevoda frazalnih glagola, kolokacija i idiomatskih izraza čije značenje nije skup značenja sastavnica izraza, nego najčešće ima preneseno značenje. U takvim je slučajevima izvrsno poznavanje izvornoga jezika, i to najčešće njegovih nestandardnih varijanti, od krucijalne važnosti. Drugim riječima, prijevod je spomenutih još uvijek neprikladan za strojno prevođenje.

Nadalje, brojni su primjeri uporabe tehnike doslovnoga prijevoda, što je nerijetko rezultiralo iskrivljivanjem ili potpunim nerazumijevanjem rečenice. U ovome kontekstu, kod alata Yandex, zabilježili smo i uporabu ćiriličnoga pisma koje je potpuno nečitljivo i nerazumljivo govornicima hrvatskoga jezika. Posljednje, iako nimalo najmanje važno, zbog razlike dvaju jezika u uporabi interpunkcijskih znakova, točnije točke kod rednih brojeva, u nekoliko smo primjera zabilježili potpunu promjenu značenja zbog izostanka interpunkcijskoga znaka točke, odnosno zbog izjednačavanja s engleskim jezikom u kojemu se ne koristi točka iza rednih brojeva.

Nakon provedene analize, možemo zaključiti da su sva tri alata za strojno prevođenje upotrebljiva, no više kao pomoć u prevođenju, nego kao sredstvo prevođenja jer prevoditelj mora učiniti brojne intervencije nakon strojnoga prevođenja. Na temelju usporedne analizu triju alata, kvalitete prijevoda tekstova, brojnosti i vrste pogrešaka, možemo zaključiti da je Google translate najkorektniji alat za strojno prevođenje. Nadalje, od triju vrsta analiziranih tekstova, najmanje je pogrešaka i prijevodnih problema bilo prilikom prevođenja izvornoga znanstvenoga članka. Razlog tomu, vjerojatno je u uporabi formalnoga standardnoga engleskoga jezika i egzaktnoga znanstvenoga stila pisanja koji rijetko sadrži za prijevod najproblematičnije frazalne glagole, kolokacije i idiomatske izraze.

Na kraju možemo zaključiti da su alati za strojno prevođenje dobra pomoć u prevođenju koje ipak zahtijeva intervenciju prevoditelja. Također, potrebna je uska suradnja jezičara i programera u oblikovanju unutarnjega rječnika i poboljšavanju kvalitete alata za strojno

prevođenje. Budući da je potreba za prevođenjem iz dana u dan sve veća, valja se nadati kako alati za strojno prevođenje neće predstavljati samo pomoćni alat ljudskom prevođenju, nego da će u strogo ograničenim, unaprijed poznatim ili pripremljenim leksičkim, morfosintaktičkim, pragmalingvističkim i diskurznim uvjetima biti u stanju proizvesti prijevod koji neće zahtijevati intervenciju prevoditelja. Dakle, ostaje pitanje do koje se granice može automatizirati prevođenje, odnosno koliko se može automatizirati razmišljanje.

7.1. Ograničenja istraživanja

Ovo istraživanje ima svoja ograničenja u tome što mu je ograničen korpus te se zaključci ne mogu generalno primijeniti, ali ukazuju na određene manjkavosti alata za strojno prevođenje.

7.2. Prijedlozi za buduća istraživanja i primjenjivost rezultata

Buduća istraživanja u području strojnoga prevođenja mogu se izravno nastaviti na provedeno istraživanje na način da se sačini veći korpus istraživanja, čime će i rezultati biti relevantniji. Također, osim triju analiziranih alata za strojno prevođenje, u buduću analizu mogu se uključiti i drugi alati. Rezultate ovoga i sličnih istraživanja mogu koristiti programeri prilikom sastavljanja unutarnjih rječnika alata za strojno prevođenje.

LITERATURA

[1] V. Ivir. *Teorija i tehnika prevođenja*. Sremski Karlovci: Centar "Karlovačka gimnazija" Sremski Karlovci, 1978.

[2] D. Arnold, L. Balkan, S. Meijer, R.L. Humphreys, L. Sadler. *Machine translation: an introductory guide*. NCC Blackwell, London, 1994. Dostupno na: http://promethee.philo.ulg.ac.be/engdep1/download/bacIII/Arnold%20et%20al%20Machine%20Translation.pdf [11.06.2017.]

[3] J. C. Catford. *A Linguistic Theory of Translation.* Oxford University Press, London, 1976.

[4] E. A. Nida, C. R. Taber. *The Theory and Practice of Translation.* E. J. Brill, Leiden, 1982.

[5] W. Koller. The concept of equivalence and the object of translation studies. *Target* 7 (2), 191–222, 1995.

[6] M. Snell-Hornby. *Translation Studies: an Integrated Approach.* John Benjamins, Amsterdam and Philadelphia, 1988.

[7] E. Gentzler. *Contemporary Translation Theories.* Routledge, New York, 1993.

[8] A. Pym. *Translation and Text Transfer: An Essay on the Principle of Intercultural Communication*. Peter Lang, Frankfurt am Main, 1992.

[9] M. Baker. *In Other Words: a Coursebook on Translation*. Routledge, London/New York. 2001.

[10] A. Newman. The contrastive analysis of Hebrew and English dress and cooking collocations: some linguistic and pedagogic parameters. *Applied Linguistics* 9(3), (293-305), London, 1988.

[11] W. J. Hutchins. *Concise history of the language sciences: from the Sumerians to the cognitivists.* U E.F.K.Koerner i R.E.Asher, (431-445), Pergamon Press, Oxford, 1995. Dostupno na: http://hutchinsweb.me.uk/ConcHistoryLangSci-1995.pdf [12.06.2017.]

[12] L. Dostert. *Brief History of Machine Translation Research.* Georgetown University, Washington, 1957.

[13] W. J. Hutchins. *Machine translation: a concise history.* Dostupno na: http://www.hutchinsweb.me.uk/CUHK-2006.pdf [13.06.2017.]

[14] Y. Bar-Hillel. The present status of automatic translation of languages. *Advances in Computers.* 1 (91-163). 1960.

[15] ALPAC. *Language and machines: computers in translation and linguistics.* DC: National Academy of Sciences, Washington, 1966.

[16] W. J. Hutchins. *Machine translation: past, present, future.* Ellis Horwood, New York, 1986.

[17] J. P. Turian, L. Shen, I. D. Melamed. Evaluation of Machine Translation and its Evaluation. *Zbornik MT Summit IX*, New Orleans, USA, 386-393, 2003.

[18] S. Oladipo Kolawole. Is every bilingual a translator? *Languge and Communication*, 16(2), 2012.
Dostupno na: http://translationjournal.net/journal/60bilingual.htm [14.06.2017.]

[19] J. Gabriel. 10 online translation tools recommended by translators. *Gengo Community blog*. 2016. Dostupno na: https://blog.gengo.com/10-online-translation-tools-recommended-translators/ [21.08.2017.]

[20] Alat za strojno prevođenje Bing
Dostupno na: https://www.bing.com/translator [14.06.2017.]

[21] Alat za strojno prevođenje Google Translate
Dostupno na: https://translate.google.hr/m/translate?hl=hr [15.06.2017.]

[22] Alat za strojno prevođenje Yandex
Dostupno na: https://translate.yandex.com/

[23] Karakteristike Yandex.Translate
Dostupno na: https://en.m.wikipedia.org/wiki/Yandex.Translate [15.06.2017.]

[24] Usporedba alata za strojno prevođenje
Dostupno na: https://www.neno-translate.com/en/, [14.06.2017.]

SAŽETAK

U svijetu globalizacije gdje je sve veća potreba za internacionalizacijom, također raste i potreba za prevoditeljskim uslugama. Ljudski je prevoditelj zbog svojih kompetencija nezamjenjiv, no budući da vremenski čimbenik igra veliku ulogu, korištenje informacijsko-komunikacijske tehnologije predstavlja značajnu potporu i zasigurno ubrzava proces i isporuku prijevoda. Rad započinje definiranjem nužnih pojmova iz područja strojnoga prevođenja i ukazivanjem na važnost automatizacije procesa prevođenja. Objašnjene su najvažnije karakteristike strojnoga prevođenja i dan je kratki povijesni pregled razvoja strojnoga prevođenja. Za potrebe ovoga diplomskoga rada, odabrana su tri besplatna alata za strojno prevođenje *Google Translate*, *Bing Translator* i *Yandex Translate* kojima su analizirane tri tematski različite vrste radova – izvorno-znanstveni članak, popularno-znanstveni članak i novinski članak. Svi članci obrađuju neku od podtema računarstva. Metodom nasumičnoga odabira, izabrano je 15 rečenica koje su, nakon prijevoda svih triju alata za strojno prevođenje, analizirane na morfološkoj, sintaktičkoj, semantičkoj i leksičkoj razini. Rezultati analize pokazuju kako je najprecizniji alat za strojno prevođenje *Google Translate*, dok je najbolje prevedeni tekst izvorno-znanstveni rad. Razlog tome jest tipična ustaljenost jezičnoga izražavanja bez učestalih uporaba frazalnih glagola, kolokacijskih i idiomatskih struktura koje su zahtjevne i često problematične za prijevod. Za njih se u obzir mora uzeti i kontekst te imati više znanja od poznavanja dvaju jezika, odnosno enciklopedijsko ili znanje o svijetu, što alati za strojno prevođenje nemaju.

Ključne riječi: *strojno prevođenje, Google Translate, Bing Translator, Yandex Translate, jezična analiza*

ABSTRACT

Globalization has resulted in internationalization of written discourse and consequently a growing need for translating services. Due to his competencies, a translator is irreplaceable. However, since short deadlines are significant factors in translating, the use of information and communication technologies is of utmost importance and provides a considerable support thus speeding up the process of translation. The paper starts with defining a machine translation terminology and pointing to the importance of automizing the translation process. The most important characteristics of machine translation are elaborated on followed by a short developmental overview of machine translation. For the purpose of this paper, three free tools for machine translation, namely *Google Translate*, *Bing Translator* and *Yandex Translate* are selected. The tools are used to translate three types of papers – an original research paper, a popular-scientific paper and a newspaper article. All three papers deal with issues in the field of computer science. Using a simple random sampling method, 15 sentences were selected to be analyzed on a morphological, syntactical, semantical and lexical level. The results point to *Google Translate* being the most efficient machine translation tool and the best translated text is the original scientific paper. The latter result may be explained with a typical scientific linguistic expression containing fewer phrasal verbs, collocations and idiomatic structures all of which are challenging and problematic for translation. To paraphrase, one needs to consider the context of such sentences and demonstrate more than solely the knowledge of two languages, i.e. one needs to acquire encyclopedic knowledge, which tools for machine translation are unable to gain.

Keywords: *machine translation, Google Translate, Bing Translator, Yandex Translate, linguistic analysis*

Životopis

Dragana Popadić rođena je u Osijeku, 12. travnja 1990. godine. Po završetku osnovne škole „Fran Krsto Frankopan" upisuje „Ekonomsku školu" u Osijeku, smjer ekonomist. Nakon završene srednje škole, upisuje preddiplomski studij, smjer Računarstvo na Elektrotehničkome fakultetu u Osijeku (danas Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek). Nakon završetka preddiplomskog studija i kratke stanke, 2015. godine upisuje diplomski studij, smjer Računalno inženjerstvo.

8. PRILOZI

Prijevodi izvornoga znanstvenoga članka

IZVORNIK NA ENGLESKOME JEZIKU	PRIJEVOD NA HRVATSKI JEZIK
GOOGLE TRANSLATE	**GOOGLE TRANSLATE**
Camera based assistance systems for the blind and visually impaired are still in a preliminary stage. Image processing techniques have already been used for the obstacle detection but the real-time processing still significantly depends on the input image resolution. This paper elaborates on the problem of staircase detection for the blind and visually impaired emphasizing the input image resolution. The evaluation of successful staircase detection is made by using different input resolutions. Choosing the appropriate input resolution is crucial to achieve optimal performance and find the compromise between accuracy and processing speed. The experiment is conducted on a dataset of frames in 5	Sustavi pomoći za slijepe i slabovidne osobe koji se temelje na kameri još uvijek su u preliminarnoj fazi. Tehnike obrade slike već su korištene za detekciju prepreka, no obrada u stvarnom vremenu značajno ovisi o razlučivosti ulaznih slika. Ovaj rad razrađuje problem otkrivanja stuba za slijepe i slabovidne osobe s naglaskom na rezoluciji ulaznih slika. Evaluacija uspješnog otkrivanja stubišta izrađena je korištenjem različitih rezolucija ulaza. Odabir odgovarajuće rezolucije ulaza ključan je za postizanje optimalnih performansi i pronalaženje kompromisa između točnosti i brzine obrade. Eksperiment se provodi na datoteci okvira u 5 različitih razlučivosti snimljenih iz video sekvenci. Danas smo svjedoci povećane

different resolutions taken from video sequences. Nowadays, we are witnessing an increased availability of high resolution video and image capturing devices. Small devices like digital cameras and smartphones are widely available and have the capability to capture high resolution and high quality videos and images. Their size makes them appropriate to use in camera based assistance systems. However, the processing of high-resolution videos or images is time-consuming and requires a significant amount of computing power. In order to achieve sufficient reliability of the camera based assistance system it is necessary to choose appropriate input image resolution. For this purpose we made an evaluation of performance in image processing and analysis using different image resolutions. Evaluation is made on the method for staircase detection which is tailored for use in assistance systems for the blind and visually impaired. This method is proposed earlier in [I] where preliminary performance results are given using input videos captured in640x360 resolution. The method is now modified for processing on various input resolutions from 90x 160 to1080x1920 pixels and influence of the input resolution on the accuracy and speed is measured. The main goal is to find the lowest resolution with acceptable detection accuracy using this method for staircase detection because lower resolutions significantly reduce execution time. It is also important to distinguish whether the higher resolutions necessarily give better detection rates.	dostupnosti uređaja za snimanje videozapisa i slika visoke rezolucije. Mali uređaji poput digitalnih fotoaparata i pametnih telefona široko su dostupni i imaju mogućnost snimanja visokokvalitetnih videozapisa i slika visoke kvalitete. Njihova veličina ih čini prikladnim za upotrebu u sustavima pomoći na kameri. Međutim, obrada videozapisa ili slika visoke rezolucije traži puno vremena i zahtijeva značajnu količinu računalne snage. Kako bi se postigla dostatna pouzdanost sustava pomoći na kameri potrebno je odabrati odgovarajuću razlučivost ulaznih slika. U tu smo svrhu napravili ocjenu izvedbe u obradi slike i analizama pomoću različitih rezolucija slike. Procjenjuje se metoda za otkrivanje stubišta koja je prilagođena za uporabu u sustavima pomoći slijepim i slabovidnim. Ova je metoda predložena ranije u [I] gdje su preliminarni rezultati izvedbe pomoću ulaznih videozapisa snimljenih u razlučivosti 640x360. Metoda je sada izmijenjena za obradu na različitim ulaznim razlučivostima od 90x 160 do 1080x1920 piksela, a utjecaj rezolucije ulaza na točnost i brzinu se mjeri. Glavni je cilj pronaći najnižu razlučivost s prihvatljivom točnosti detekcije pomoću ove metode za otkrivanje stubišta jer niže rezolucije značajno smanjuju vrijeme izvršenja. Također je važno razlikovati jesu li veće rezolucije nužno dale bolje stope detekcije
BING TRANSLATOR	**BING TRANSLATOR**
	Kamera na temelju pomoć sustava za slijepe i slabovidne osobe su još uvijek u pripremnoj fazi. Tehnike obrade slika već se koriste za otkrivanje prepreka ali obrada u realnom vremenu još uvijek značajno ovisi o ulaznu sliku rezolucije. Ovaj rad obrađuje problem prepoznavanja stubište za slijepe i slabovidne osobe naglašavajući ulaznu sliku rezolucije.

	Procjena uspješnog stubište otkrivanje je napravio pomoću različitih ulaznih razlučivosti. Odabir odgovarajuće ulazna razlučivost je ključno za postizanje optimalne performanse i pronaći kompromis između točnosti i brzine obrade. Pokus se provodi skup podataka u 5 različitih razlučivosti iz video sekvenci. Danas, svjedoci smo povećane dostupnosti visoka rezolucija video i predodžba hvatanje uređaji. Mala sprava poput koji se tiče prsta kamera i smartphones su široko dostupni i imati sposobnost to hvatanje visoka razlučivost i visoke kvalitete videa i slika. Njihova veličina ih čini prikladno da koriste sustave u kameru na temelju pomoći. Međutim, obradu visoke rezolucije videa ili slika je dugotrajan i zahtijeva značajnu količinu računalnu snagu. Kako bi se postigla dovoljna pouzdanost kamere temeljen pomoć sistem je potrebno izabrati odgovarajuću ulaznu sliku rezolucije. U tu svrhu smo napravili procjenu učinka u obrada slike i analize koristeći različite slike rezolucije. Obavlja na način za otkrivanje stubišta koji je prilagođen za uporabu u sustavima pomoći za slijepe i slabovidne osobe. Ova metoda je predloženo ranije u [I] gdje su dani preliminarni performanse rezultati koristeći ulazni video hvatanje in640x360 rješenje. Metoda je sada promjene na obradu na različite ulazne rezolucije od 90 x 160 to1080x1920 piksela i utjecaj ulazna razlučivost na točnost i brzina se mjeri. Glavni cilj je pronaći najniže rezolucije s prihvatljivim otkrivanje točnost koristeći ovu metodu za otkrivanje stubište jer niže razlučivosti značajno smanjiti vrijeme izvršavanja. Također je važno razlučiti da li više razlučivosti daje bolje otkrivanje mjera.
YANDEX TRANSLATE	**YANDEX TRANSLATE**
	Sustavi kamera sustava skrbi za slijepe i slabovidne još uvijek u preliminarnoj fazi. Metode obrade slike već su korišteni za otkrivanje prepreka, a snimanje u realnom vremenu još uvijek uvelike ovisi o rezoluciji ulazne slike. Ovaj dokument opisuje problem

	otkrivanje stepenice za slijepe i slabovidne naglašavajući rezoluciju ulazne slike. Rezultat uspješnog otkrivanja stepenice ostvariti s različitim rezolucijama unosa. Odabirom prikladno razlučivost ulaznog signala od presudne je važnosti za postizanje optimalne performanse i pronaći kompromis između preciznosti i brzine obrade. Eksperiment se održava skup kadrova u 5 različitim rezolucijama preuzet iz video sekvence. U današnje vrijeme smo svjedoci povećana dostupnost video visoke rezolucije i uređaj za snimanje slike. Manji uređaji, kao što su digitalni fotoaparati i pametne telefone široko dostupni i imaju priliku da iskoriste visoku rezoluciju i vrhunsku kvalitetu video i slike. Njihova veličina ih čini pogodnim za uporabu u kamere sustav pomoći. Međutim, obradom video visoke rezolucije ili slike potrebno je puno vremena i zahtijeva znatnu količinu računalne snage. Kako bi postigli dovoljnu pouzdanost sustava kamere pomoć, potrebno je odabrati odgovarajuću dozvolu ulazne slike. Za tu svrhu napravili smo procjenu performansi u oblasti obrade slike i analize pomoću raznih dozvola slike. Procjena se vrši na temelju metoda za otkrivanje stubište, koji je dizajniran za korištenje u sustavima skrbi za slijepe i slabovidne. Ova metoda je ranije predložila u [I], gdje je preliminarni rezultati se izdaju preko puštanje video rezolucija in640x360. Sada ova metoda je modificirana za obradu na različite dozvole ulaznog signala od 90x 160 to1080x1920 piksela i utjecaj razlučivost ulaznog signala na točnost i brzina se mjeri. Glavni cilj-pronaći najniže rezolucije sa prihvatljivom preciznošću detekcije, koristeći ovu metodu za otkrivanje stepenice-za niske rezolucije, znatno će smanjiti vrijeme izvršavanja. Također je važno razlikovati je li i u višoj rezoluciji nužno će najbolje performanse detekcije.

Prijevodi popolarno-znanstvenoga članka

IZVORNIK NA ENGLESKOME JEZIKU	PRIJEVOD NA HRVATSKI JEZIK
GOOGLE TRANSLATE	**GOOGLE TRANSLATE**
Imagine taking a time machine back to 1750—a time when the world was in a permanent power outage, long-distance communication meant either yelling loudly or firing a cannon in the air, and all transportation ran on hay. When you get there, you retrieve a dude, bring him to 2015, and then walk him around and watch him react to everything. It's impossible for us to understand what it would be like for him to see shiny capsules racing by on a highway, talk to people who had been on the other side of the ocean earlier in the day, watch sports that were being played 1,000 miles away, hear a musical performance that happened 50 years ago, and play with my magical wizard rectangle that he could use to capture a real-life image or record a living moment, generate a map with a paranormal moving blue dot that shows him where he is, look at someone's face and chat with them even though they're on the other side of the country, and worlds of other inconceivable sorcery. This is all before you show him the internet or explain things like the International Space Station, the Large Hadron Collider, nuclear weapons, or general relativity. This experience for him wouldn't be surprising or shocking or even mind-blowing—those words aren't big enough. He might actually die. But here's the interesting thing—if he then went back to 1750 and got jealous that we got to see his reaction and decided he wanted to try the same thing, he'd take the time machine and go back the same distance, get someone from around the year 1500, bring him to 1750, and show him everything. And the 1500 guy would be shocked by a lot of things—but he wouldn't die. It would be *far* less of an insane experience for him, because	Zamislite uzimanje vremenskog stroja natrag do 1750. godine - vrijeme kada je svijet bio u stalnom nestanku struje, komunikacija na dalekoj udaljenosti značila je glasno vikati ili pucati u zrak, a sav prijevoz krenuo je na sijeno. Kad dođete, dohvatite dude, dovedite ga do 2015. godine, a zatim ga prošetajte i gledajte ga da reagira na sve. Nemoguće je da razumijemo kako bi mu bilo da vidi sjajne kapsule koje se natječu na autocesti, razgovaraju s ljudima koji su bili s druge strane oceana ranije ujutro, gledaju sportove na kojima se igraju tisuću milja , Čuti glazbenu izvedbu koja se dogodila prije 50 godina i igrati sa svojim čarobnim pravokutnikom čarobnjaka koji je mogao upotrijebiti za snimanje slike stvarnog života ili snimanje živućeg trenutka, generiranje karte s paranormalno pokretnom plavom točkom koja mu pokazuje gdje se nalazi , Pogledati nečije lice i razgovarati s njima, iako su na drugoj strani zemlje, i svjetovi drugih nezamislivih čarobnjaštva. Sve je to prije nego što mu pokažete internet ili objasnite stvari poput Međunarodne svemirske postaje, Large Hadron Collidera, nuklearnog oružja ili opće relativnosti. Ovo iskustvo za njega ne bi bilo iznenađujuće ili šokantno ili čak i umom - te riječi nisu dovoljno velike. Mogao bi umrijeti. Ali ovdje je zanimljiva stvar - ako se vratio natrag do 1750. godine i postao ljubomoran kad smo vidjeli njegovu reakciju i odlučili je pokušati ista stvar, preuzeti vremenski stroj i vratiti se na istu udaljenost, dobiti nekoga iz Oko 1500. godine, dovesti ga do 1750. i pokazati mu sve. A 1500 čovjek bi bio šokiran mnogim stvarima - ali on ne bi umro. Za njega bi bilo daleko manje ludog iskustva, jer su 1500. i 1750. bili vrlo različiti, bili su mnogo manje različiti od 1750. do 2015.

while 1500 and 1750 were very different, they were *much less* different than 1750 to 2015. The 1500 guy would learn some mind-bending shit about space and physics, he'd be impressed with how committed Europe turned out to be with that new imperialism fad, and he'd have to do some major revisions of his world map conception. But watching everyday life go by in 1750—transportation, communication, etc.—definitely wouldn't make him die.	godine. 1500 čovjek bi naučio nešto o savijanju sile o prostoru i fizici, bio bi Impresioniran s koliko je Europa postala predodređenom tom novom imperijalizmu, i morat će napraviti neke velike izmjene svoje koncepcije karte svijeta. Ali promatranje svakodnevnog života prolazilo je 1750. godine - prijevoz, komunikacija, itd. - definitivno ga ne bi natjeralo da umre.
BING TRANSLATOR	**BING TRANSLATOR**
	Zamislite voditi vremenski stroj u 1750 — vrijeme kad je svijet bio u trajne struje na daljinu komunikacija mislio vikati glasno ili pucanje topova u zraku i svim prijevoza ran na sijeno. Kada se tamo, dohvaćanje muško, dovesti ga do 2015., i onda neka hoda i paziti na njega reagiraju na sve. To je nemoguće za shvatiti kako bi bilo da vidim sjajnu kapsule utrke na autocesti, razgovarati s ljudima koji su bili na drugoj strani oceana ranije u danu, gledajte sport kojim 1000 milja daleko, slušanje glazbene izvedbe koja se dogodila prije 50 godina i igrati s moj čarobni čarobnjak pravokutnik koji on treba uhvatiti sliku stvarnog života ili snimiti trenutak života , generirati karta paranormalne kreće plavom točkom koja mu pokazuje gdje je nečije lice i razgovor s njima iako su na drugoj strani zemlje i svjetova druge nezamislivo čarobnjaštva. Ovo je sve prije nego li ga na internetu ili objasniti stvari kao što su međunarodna svemirska postaja, Large Hadron Collider, nuklearnog oružja ili opće relativnosti. Ovo iskustvo za njega ne bi bilo iznenađujuće ili šokantan ili čak um puše — te riječi nisu dovoljno veliki. Mogao bi stvarno umrijeti. Ali ovdje je zanimljiva stvar, ako je onda se vratio u 1750 i ljubomoran da smo vidjeli njegovu reakciju i odlučio da će pokušati isto, bi se vremeplov i vratiti ista udaljenost, dobiti netko od oko 1500 godina, dovesti ga do

	1750, te mu sve pokazati. I 1500 tip Šokirat puno stvari, ali ne bi umro. Bilo bi daleko manje ludo iskustvo za njega, jer dok 1500 i 1750 bili su vrlo različiti, oni su mnogo manje razlikuje od 1750 do 2015. 1500 tip bi naučiti sranje um-savijanje prostora i fizike, je impresioniran s naš Europe pokazala se sa taj novi imperijalizam hir i morao bi raditi neke velike izmjene začeću kartu svijeta. Ali gledajući svakodnevni život ići 1750-prijevoz, komunikacije, itd — definitivno bi ga umrijeti.
YANDEX TRANSLATE	**YANDEX TRANSLATE**
	Zamislite automobil vremena još 1750—vrijeme, kada je svijet bio u stalnom nestanka struje, međugradske veze značilo ili glasno vikati ili pucnjava iz pištolja u zrak, i sva vozila naletio na sijeno. Kada dođete tamo, dobijete dude, dovesti ga do 2015. godine, a zatim ga prođe oko sebe i vidjeti kako reagira na sve. To je nemoguće za nas da shvatimo, da bi se za njega, da vidi sjajnu kapsule utrke na autocesti, razgovarati s ljudima koji su bili na drugoj strani oceana ranije isti dan, sat i sportske, koji su igrali 1000 milja, čuti glazbeni nastup, što se dogodilo prije 50 godina, i igrati s mojim čarobni master pravokutnik, koji je mogao koristiti za snimanje u stvarnom životu slike ili snimiti žive u trenutku, stvoriti kartu s nadnaravno kreće plava točka, koja pokazuje mu gdje se nalazi, gledamo na nečijem licu i komunicirati s njima, čak i ako oni na drugom kraju zemlje, i svjetove drugih nedokučiva magije. To je sve, prije nego što ga pokaže na internetu ili objasniti takve stvari kao što je Međunarodna Svemirska postaja, veliki hadronski sudarač, nuklearno oružje, ili opće teorije relativnosti. To iskustvo je za njega neće biti strašan, ili je šokantna ili čak взрывает mozak—te riječi nisu dovoljno velike. On je, u stvari, može umrijeti. Ali to je velika stvar—ako se vratio na 1750 i

	приревновал da smo stigli, da vidi njegove reakcije, i on je odlučio pokušati isto, da bi se vremenski stroj i vratiti se na istu udaljenost, uzeti nekoga od oko 1500, dovesti ga do 1750, i pokazati mu sve. I 1500 čovjek će biti u šoku od mnogih stvari—ali on ne umire. To bi bilo mnogo manje mad iskustvo za njega, jer pri 1500 i 1750 bili su vrlo različiti, oni su mnogo manje različiti, od 1750 do 2015 godine. U 1500 momak htio naučiti neke halucinogena sranja o svemiru i fizici, on bi bio impresioniran kako je napredovao u Europi se ispostavilo da je s novog imperijalizma пунктик, i on mora napraviti neke velike promjene svoj svjetonazor karti. Ali gledajući u svakodnevnom životu u 1750—transport, komunikacije i sl. sigurno ne bi mu umrijeti.

Prijevodi novinskoga članka

IZVORNIK NA ENGLESKOME JEZIKU	PRIJEVOD NA HRVATSKI JEZIK
GOOGLE TRANSLATE	**GOOGLE TRANSLATE**
An Uber executive accused of stealing driverless car technology from his former employers at Google is exercising his Fifth Amendment right to avoid self-incrimination, according to his lawyers. The lawyers for Anthony Levandowski, the former head of Google's self-driving car project who is now leading a similar effort at Uber, said he was broadly asserting his Fifth Amendment rights because there was "potential for criminal action" in the case, according to court transcripts obtained on Thursday. The legal maneuver adds even more intrigue to the high-profile fight between two of the technology industry's largest companies, which are squaring off in the race to put driverless cars on the road.	Uber izvršni optužen za krađu automobilske tehnologije bez vozača od njegovih bivših poslodavaca u Googleu provodi svoje pravo peti amandmana kako bi izbjegao samoubojstvo, prema njegovim odvjetnicima. Odvjetnici za Anthony Levandowski, bivši šef Googleovog autoprojekta koji sada vodi sličan napor u Uberu, izjavio je da široko tvrdi svoje pravo peti amandmana jer je u tom slučaju "potencijal za kazneno djelo", prema Sudski zapisi dobiveni u četvrtak. Pravni manevar još više ulijeva intrigu na borbu visokih profila između dviju najvećih tvrtki u tehnološkoj industriji, koje se kvare u utrci za stavljanje automobila bez vozača na cestu.

Mr. Levandowski is at the center of a lawsuit between Uber and Waymo, which was spun out from Google to become its own Alphabet subsidiary. Waymo has accused Mr. Levandowski of stealing documents and poaching employees before quitting Google and then colluding with Uber to use that technology to advance driverless car efforts at the ride-hailing service. Shortly after leaving Google, Mr. Levandowski started his own self-driving truck start-up, Otto. Six months after Otto was formed, Uber acquired the company for $680 million. Waymo filed a motion seeking a temporary injunction this month to stop Uber's autonomous vehicle development. As part of the motion seeking the injunction, Waymo said that Mr. Levandowski, while still working at Google, installed software that allowed him to download over 14,000 files, or about 9.7 gigabytes of data, pertaining to the driverless car program. Uber was ordered to hand over those files.	G. Levandowski nalazi se u središtu tužbe između Ubera i Wayma, koji je izradio Google da bi postala njezina podružnica Alfabeta. Waymo je optužio g. Levandowskog da je krao dokumente i krivolovao zaposlenike prije odustajanja od Googlea, a zatim se sudario s Uberom kako bi upotrijebio tu tehnologiju kako bi unaprijedio nastojanja automobila bez vožnje u usluzi vožnje. Nedugo nakon što je napustio Google, g. Levandowski započeo je vlastiti start za vozilo s autopilotom, Otto. Šest mjeseci nakon što je Otto formiran, Uber je kupio tvrtku za 680 milijuna dolara. Waymo je ovog mjeseca podnio zahtjev koji traži privremenu zabranu zaustavljanja Uberovog autonomnog razvoja vozila. U sklopu prijedloga koji traži sudsku zabranu, Waymo je rekao da je g. Levandowski, dok je još radio na Googleu, instaliran softver koji mu je omogućio preuzimanje preko 14.000 datoteka, odnosno oko 9,7 gigabajta podataka, koji se odnose na automobilski program vozača. Uberu je naređeno da preda te datoteke.
In the transcript of a private hearing before Judge William Alsup in United States District Court in San Francisco, Mr. Levandowski's lawyers said he was invoking his Fifth Amendment right to avoid self-incrimination in not turning over documents that may pertain to the case. Arturo Gonzalez, one of Uber's lawyers, said they have made clear to Mr. Levandowski that he needs to release any documents relevant to the case as part of discovery. "We obviously have a conflict," he said. Miles Ehrlich, one of the lawyers representing Mr. Levandowski, said the Uber executive was asserting his Fifth Amendment rights to protect against "compelled disclosure that would identify the existence, location or possession of any responsive documents." He also said that Mr. Levandowski's decision to invoke the Fifth Amendment may change as they examine the case.	U transkriptu privatne rasprave pred sucem Williamom Alsupom u Okružnom sudu Sjedinjenih Država u San Franciscu, odvjetnici g. Levandowskija rekli su da se poziva na njegovo pravo peti amandmana kako bi izbjegao samokrunjavanje u tome da ne preokrene dokumente koji se mogu odnositi na slučaj. Arturo Gonzalez, jedan od Uberovih odvjetnika, izjavio je da su gospodinu Levandowskom objasnili da treba objaviti sve dokumente relevantne za slučaj kao dio otkrića. "Mi očito imamo sukob", rekao je. Miles Ehrlich, jedan od odvjetnika koji zastupa g. Levandowskija, izjavio je kako je izvršna vlast Ubera potvrdila svoje pravo pete izmjene radi zaštite od "prisilnog otkrivanja koji bi identificirao postojanje, smještaj ili posjedovanje bilo kakvih odgovarajucih dokumenata." Također je rekao da je gospodin Levandowski Odluka da se pozove na petu dopunu može se mijenjati

	dok pregledavaju slučaj.
BING TRANSLATOR	**BING TRANSLATOR**
	Uber izvršni optužen za krađu Svjetlopropusni automobila tehnologija od svojih bivših poslodavaca na Google je vježbanje desnoj peti amandman kako bi se izbjeglo samooptuživanja, prema njegovi odvjetnici. Odvjetnici za Anthony Levandowski, bivši šef Google samostalno vozi auto projekt koji je sada vodeći sličan napor na Uber, rekao je on široko govori njegov peti amandman prava zato što je "potencijal za kriminalnih akcija" u slučaju, prema sudskih zapisnika dobivenih u četvrtak. Pravni manevar dodaje još više intriga visoka borba između dva tehnologija industrija najvećih kompanija, koje se natječu se u utrci staviti Svjetlopropusni automobila na cesti. Gospodin Levandowski je u središtu tužbe Uber i Waymo, koja je urađena od Google postati abeceda kćer. Waymo je optužio g. Levandowski krađa dokumenata i krade zaposlenika prije odvikavanje od Google i onda suraduje sa Uber koristiti tu tehnologiju unaprijed Svjetlopropusni auto napore na vožnju Pozdravljajući usluga. Ubrzo nakon izlaska Google, g. Levandowski počeo svoje samostalno vožnje kamiona start-up, Otto. Šest mjeseci nakon Otto je formiran, Uber stečene tvrtke za 680 milijuna dolara. Waymo podnio prijedlog traže privremenu zabranu ovaj mjesec da se zaustavi razvoj autonomnih vozila Uber's. Kao dio pokreta koji traže zabranu, Waymo je rekao da g. Levandowski, dok je još radio u Google, instaliran softver koji ga to preuzimanje datoteka više od 14.000 datoteke ili oko 9.7 gigabajta podataka, koji se odnose na Svjetlopropusni auto program. Uber je naređeno da predaju tih datoteka. U prijepis privatne rasprave prije nego što sudac William Alsup u SAD-u okružnom sudu u San Franciscu, gospodin Levandowski

	odvjetnici rekao je zazivajući desnoj peti amandman kako bi se izbjeglo samooptuživanja u ne okreće na dokumente koji se možda odnose na slučaj. Arturo Gonzalez, jedna Uber's odvjetnika, rekao da su jasno da gospodin Levandowski što mu je potrebno za puštanje bilo koji dokumenti relevantni za slučaj kao dio otkriće. "Očito imamo sukob", rekao je on. Miles Ehrlich, jedan od odvjetnika koji zastupaju g. Levandowski, rekao je Uber izvršni govori njegov peti amandman prava za zaštitu protiv "primoran otkrivanja koji bi identificirao postojanje, mjesto ili posjedovanje od bilo koji odgovarajući dokumenti." Rekao je da gospodin Levandowski odluka da se pozovu peti amandman može promijeniti kao što se ispita slučaj.
YANDEX TRANSLATE	**YANDEX TRANSLATE**
	Izvršni uber optužen za krađu tehnologije bez posade vozila od svog bivšeg poslodavca u Google koristi svoje pravo na peti amandman, kako bi se izbjeglo самооговора, prema riječima njegovog odvjetnika. Odvjetnici Ante Левандовского, bivši šef Google samostalno vožnje automobila projekta, koji sada vodi sličnu aktivnost u ladicu, rekao je da je bio široko tvrdeći da je njegov peti amandman prava, jer nije bilo mogućnosti za kriminalne aktivnosti" u slučaju da, prema sudskim protokolima su dobiveni u četvrtak. Pravni manevar dodaje još više intriga u glasnijem borba između dva od najvećih kompanija u industriji visoke tehnologije, koje se protive u utrci staviti vozača automobila na cesti. Gospodin Левандовского u središtu bitke između uber i Waymo, koji je bio izdvojen iz Google postati svojih podružnica abecede. Waymo optužio g na Левандовского u krađi dokumenata i переманивание osoblja prije odlaska Google, a zatim u dosluhu s uber koristiti ovu tehnologiju za promociju bespilotnih napore automobil voziti-grad uslugu. Ubrzo nakon odlaska iz kompanije

	Google, gospodin Левандовского započeo svoju samostalnu vožnju pokretanje kamiona, Otto. Šest mjeseci nakon Otto je formirana, uber kupio tvrtku za $680 milijuna Waymo podnio prijedlog za privremenu zabranu ovog mjeseca, da se zaustavi razvoj autonomnih vozila uber. U okviru zahtjev za zabranu, rekao je Waymo da g Левандовского, još uvijek radim u Google, softver, što mu je omogućilo preuzimanje više od 14.000 datoteka, ili oko 9,7 gigabajta podataka koji se odnose na programu vozača automobila. Uber je naređeno poslati ove datoteke. U стенограмме zatvorenog saslušanja sudija William Alsup u okružni sud u SAD-u u San Franciscu, odvjetnika g na Левандовского je rekao da je poziv svoje pravo na peti amandman, kako bi se izbjeglo самооговора, ne okreće na dokumente, koji se odnose na posao. Arturo Gonzalez, jedan od pravnika kompanije uber, rekao je da oni jasno g na Левандовского, koji je trebao objaviti nikakve dokumente od značaja za poslove u okviru otvaranja. "Mi smo, očito, imamo sukob", rekao je on. Milja Ehrlich, jedan od odvjetnika, koji predstavlja gospodin Левандовского, izjavio je izvršni uber je tvrdeći da je njegov peti amandman prava za zaštitu od "prisilni objavljivanje informacija, da bi se utvrdilo postojanje, lokaciju ili posjedovanje bilo kakve relevantne dokumente". On je također izjavio da je odluka g na Левандовского pozvati na peti amandman, može promijeniti, kao što su uzeti stvar.