

STROJOVÝ PREKLAD ZALOŽENÝ NA NEURÓNOVÝCH SIEŤACH – SĽUBNÁ CESTA PREKLADU Z ANALYTICKÝCH JAZYKOV DO FLEKTÍVNEJ SLOVENČINY?¹

Patrik Petráš – Daša Munková***

** Filozofická fakulta Univerzity Konštantína Filozofa v Nitre
Štefánikova 67, Nitra
E-mail: ppetras@ukf.sk*

*** Fakulta prírodných vied a informatiky Univerzity Konštantína Filozofa v Nitre
Tr. A. Hlinku 1, Nitra
E-mail: dmunkova@ukf.sk*

PETRÁŠ, P. – MUNKOVÁ, D. (2023): Machine Translation Based on Neural Networks – a Promising Way to Translate from Analytic Languages into Flective Slovak? In: *Slovenská reč*, 88/1, 74 – 89.

Abstract: In this paper, we deal with the issues of machine translation based on neural network. We explain the fundamental principles of this approach to automatic translation. Based on the analysis of statistical and neural machine translations from English into Slovak, we compare the quality, and/or the qualitative shifts after changing the approach to machine translation, from statistical to neural networks. The results reveal that neural machine translation achieves better results in fluency and grammatical correctness of translation, but the representation of semantically inadequate translations increases in examined corpus of journalistic texts.

Keywords: neural machine translation, inflectional language, analytical language, Slovak language, English language.

Článok v skratke:

- Príspevok sa venuje strojovému prekladu založenému na neurónových sieťach a vysvetľuje jeho základné princípy fungovania.
- V štúdií na vybraných príkladoch strojovo preložených publicistických textov z angličtiny do slovenčiny porovnávame kvalitu prekladu založeného na neurónových sieťach a štatistického strojového prekladu.
- Výsledky poukazujú na zlepšenie gramatickej korektnosti, resp. plynulosti prekladu založeného na neurónových sieťach, ale problémovým miestom stále zostáva sémanticko-lexikálna korektnosť výberu prekladových ekvivalentov.

¹ Táto práca bola podporovaná Agentúrou na podporu výskumu a vývoja na základe Zmluvy č. APVV-18-0473 *Klasifikačný model chybovosti strojového prekladu: krok k objektívnejšiemu hodnoteniu kvality prekladu* a Univerzitnou grantovou agentúrou UKF v Nitre č. III/11/2022 *Otázka kvalitatívneho posunu strojovo preložených textov z cudzieho jazyka do slovenčiny (porovnanie štatistického a neurónového strojového prekladu)*.

1. ÚVOD

V predchádzajúcom príspevku (Petráš – Munková 2019, s. 258 – 287) sme sa venovali problematike strojového prekladu medzi gramaticky odlišnými typmi jazykov, konkrétne išlo o translačný smer angličtina (analytický jazyk) – slovenčina (flektívny jazyk). Vysvetlili sme základné princípy fungovania strojového prekladu, pričom sme sa zamerali najmä na štatistický strojový preklad. Následne sme v exemplifikačnej časti príspevku analyzovali typické chyby, s ktorými sa evalvátori textov pri anotovaní chýb stretali. Z dôvodu komplexnosti a rozsiahlosti problematiky, ktorá doposiaľ nie je najmä v slovenských podmienkach uspokojivo preskúmaná, sme sa rozhodli na výskum nadviazať a zamerať sa na súčasnú technológiu uplatňovanú v strojovom preklade, teda na strojový preklad založený na umelej inteligencii – na neurónových sieťach a hlbokom učení sa (deep learning). Vzhľadom na veľký rozmach uvedených technológií v súčasnosti sme sa do analýz vybraných textov rozhodli zaradiť okrem neurónového strojového prekladača od spoločnosti Google (Google Prekladač) ešte dve voľne dostupné služby automatického prekladu, a to DeepL a ChatGPT. Hoci oba prekladače – Google Prekladač a DeepL – používajú umelú inteligenciu na preklad, významný rozdiel medzi nimi spočíva v rozdielnych dátach, na ktorých sú natrénované. Google Prekladač vychádza z paralelného korpusu Europarl^[1] a dopĺňa ho rôznymi digitálnymi zdrojmi z viacerých jazykov; DeepL je natrénovaný na korpuse Linguae^[2], ktorý okrem humánne preložených viet obsahuje preklady idiémov a úryvky textov, v ktorých sa slovo/fráza nachádza.^[3] Kým DeepL^[4] používa umelú inteligenciu a techniky hlbokého učenia sa na strojový preklad, ChatGPT^[5] je jazykový model pochádzajúci z generatívneho pretrénovaného transformera založeného na technikách hlbokého učenia sa a jedna z jeho aplikácií je strojový preklad.^[5] Teda všetky tri modely strojového prekladu používajú neurónové siete, ale DeepL nepoužíva transformer model pri preklade ako Google Prekladač alebo ChatGPT a ani rozsiahle jazykové modely ako ChatGPT (Kutylowski, in: Shrivastava – Kutylowski 2023).

V príspevku opíšeme základný princíp fungovania strojového prekladu, porovnáme princíp súčasnej technológie prekladu, neurónového strojového prekladu s jeho predchodcom – štatistickým strojovým prekladom. Ďalej na príklade niekoľkých textov porovnáme výsledok štatistického a neurónového strojového prekladu rovnakého východiskového textu. Na uvedených príkladoch poukážeme na zásadné rozdiely v kvalite prekladu, ako aj v typoch chýb vyskytujúcich sa pri týchto rôznych prístupoch k prekladu. Článkom sa takisto pokúsime naznačiť odpoveď na otázku, či môžu byť neurónové siete vhodnou perspektívou pre kvalitné preklady z analytickej angličtiny do flektívnej slovenčiny.

Je potrebné si uvedomiť, že strojový preklad je v súčasnosti veľmi dynamicky sa vyvíjajúcou oblasťou a strojovo preložené texty (najmä nástrojmi založenými na

neurónových sieťach) rýchlo „starnú“ (rezultát, preklad textu môže byť v rôznych časových úsekoch iný), a preto je tento príspevok sčasti i prehľadom veľmi nedávnej histórie vývoja strojového prekladu.

2. STROJOVÝ PREKLAD ZALOŽENÝ NA NEURÓNOVÝCH SIEŤACH

Strojový preklad (Machine translation, MT) je automatické konvertovanie textu z jedného prirodzeného jazyka do druhého prirodzeného jazyka. Kvalita, ktorú produkuje nástroj MT, je rozličná, pohybuje sa od veľmi vysokej až po veľmi nízku v závislosti od vnútorných (jazykových) vlastností daného textu a jazykového páru (Lihua 2022, s. 1).

V súčasnosti sa používajú nástroje MT založené na neurónových sieťach. Neurónový MT (NMT) ponúka lepšie výsledky v kvalite produktu, najmä v parametri čitateľnosti textu/prekladu ako jeho predchodca – štatistický MT (SMT). Napríklad neurónové MT Pangeanic prekladače garantujú veľmi vysokú paritu s ľudským prekladateľom (90 – 95 %) a to je jeden z dôvodov, prečo sa veľa firiem a vládnych inštitúcií v Európskej únii rozhodlo používať NMT na preklad textu.^[6] Generálne riaditeľstvo pre preklady Európskej komisie (DGT EC) dokonca vyvinulo svoj vlastný MT nástroj – eTranslation,^[7] ktorý je určený na preklad administratívnych textov.


V súčasnosti je najpoužívanejším voľne dostupným MT nástrojom Google Prekladač,^[8] ktorý sme v štúdiu použili. Neurónový Google Prekladač je založený na hlbokom učení sa (deep learning) na produkciu prekladu.

NMT sa odlišuje od svojho predchodcu – SMT – v spôsobe automatického prekladu. Automatický preklad sa skladá z troch etáp (bližšie pozri Petráš – Munková 2019, s. 265):


1. z analýzy východiskového textu, t. j. z vytvorenia abstraktnej reprezentácie východiskového textu, ktorá pozostáva zo sekvencie slov danej východiskovej vety;
2. z transferu abstraktnej reprezentácie východiskovej vety do rovnakej alebo do nižšej úrovne abstraktnej reprezentácie vety v cieľovom jazyku;
3. zo syntézy cieľového textu, t. j. z generovania zmysluplnej sekvencie slov v cieľovom jazyku (obr. 1).

Frázový štatistický strojový preklad vynecháva analýzu východiskového textu a syntézu cieľového textu, t. j. nevytvára abstraktnú reprezentáciu vo východiskovom jazyku a ani ju negeneruje v cieľovom jazyku. Strojový prekladač je schopný vytvoriť niekoľko prekladov k jednej východiskovej vete a aplikovaním štatistického prístupu vyberie najpravdepodobnejší preklad (obr. 2). Pri tomto prístupe k prekladu sa nevyužívajú rozsiahle jazykové znalosti, ale jazykové korpusy a algoritmus založený na pravdepodobnosti.

Obrázok 1: Trojuholník automatického prekladu (Source Sentence – východisková veta, Target Sentence – cieľová veta, Interlingua – umelý jazyk)^[9]



Obrázok 2: Trojuholník frázového štatistického strojového prekladu^[9]



NMT na rozdiel od SMT pozostáva nielen z transferu, ale aj z analýzy východiskového textu, v ktorej sa vytvorí ku každej vete jej vektorová reprezentácia. Následne sa priamo zo sekvencie vektorov východiskového textu (vnútornej reprezentácie východiskových viet) vytvára cieľový text (obr. 3). Navyše celý proces prekladu sa modeluje prostredníctvom neurónovej siete, ktorej kľúčovým prvkom je schopnosť automaticky opravovať svoje parametre počas tréningu. Na druhej strane, algoritmy, ktoré používa na hlboké učenie sa, umožňujú učiť sa a generovať pravidlá jazyka z preloženého textu a vytvoriť cieľový text, teda preklad. V praxi to znamená, že často sa zlepšuje **plynulosť prekladu**² na úkor **adekvátnosti prekladu**.³ NMT niekedy vyprodukuje vety, ktorých obsah sa nezhoduje s obsahom východiskového textu, čo vyúsťuje do pomerne prekvapujúcich prekladov (Pánisová – Munková 2021, s. 289).

² Koncept plynulosti je orientovaný na cieľový jazyk, t. j. do akej miery sa preklad riadi pravidlami a normami cieľového jazyka (Castilho – Doherty – Gaspari – Moorkens 2018, s. 18).

³ Koncept adekvátnosti je orientovaný na východiskový jazyk, t. j. do akej miery preklad transformuje význam východiskovej jednotky do cieľového jazyka (Castilho – Doherty – Gaspari – Moorkens 2018, s. 18).

Obrázok 3: Trojuholník neuronového strojového prekladu^[9]



3. METODOLÓGIA

Anglické východiskové texty (66 textov) sme získali v období rokov 2016 – 2017 z britského online časopisu *The Guardian*, ktoré sme neskôr tokenizovali a segmentovali. Pomocou voľne dostupného nástroja Google Prekladač sme strojovo preložili všetky anglické texty do slovenčiny. V danej dobe použitý strojový prekladač pracoval na princípe frázového štatistického strojového prekladu. Následne boli všetky texty posteditované profesionálnymi prekladateľmi v rámci workshopu zameraného na posteditáciu strojového prekladu. Okrem samotnej posteditácie sa realizoval aj ľudský preklad dvomi profesionálnymi prekladateľmi. V ďalšej fáze spracovania strojovo preložených textov sme realizovali analýzu chýb, ktoré vznikli pri strojovom preklade.

Pri kategorizácii chýb sme vychádzali z kategoriálneho rámca na hodnotenie chýb strojového prekladu (Vaňko 2017, s. 83 – 100), v ktorom autor jednotlivé chyby zadelil do nasledovných kategórií:

1. predikatívnosť vety (chyby v predikačných kategóriách – čas, spôsob; chyby v kongruenčných kategóriách – zhoda v osobe, čísle, v mennom rode);

2. modálny a komunikačný rámec vety (chyby v modálnosti, napr. negácia, nutnosť, možnosť a pod.);

3. syntakticko-sémantická korelatívnosť (najmä chyby v nominálnej a verbálnej morfosyntaxi, napr. nekorektne realizovaná menná zhoda v determinatívnej syntagme, nesprávne bezpredložkové a predložkové väzby a pod.);

4. súvetná syntax (identifikácia sémantických vzťahov medzi vetami, medzi-
vetná konektívnosť a pod.);

5. lexikálna sémantika (najmä adekvátne transfery významu slova, polysémia, homonymia a pod.).⁴

Vzhľadom na to, že v roku 2018 došlo k zmene paradigmy prekladu (zo SMT na NMT), v roku 2021 sme opätovne strojovo preložili anglické texty do slovenčiny prostredníctvom nástroja Google Prekladač, ktorý už používal umelú inteligenciu založenú na neuronových sieťach. V rámci výskumu sme zopakovali analýzu chýb neuronového strojového prekladu a následne porovnali vzniknuté chyby pri SMT a NMT.

⁴ Pri jednotlivých kategóriách uvádzame len príklady chýb, podrobnejší výpočet, ako aj presnú charakteristiku kategoriálneho rámca uvádza autor vo svojej kapitole (Vaňko 2017, s. 83 – 100).

Vytvorili sme paralelný korpus publicistických textov, ktorý pozostával:

- a) z východiskových anglických textov (VT_EN),
- b) zo štatistických strojových prekladov v slovenčine (SMT),
- c) z neurónových strojových prekladov v slovenčine (NMT),
- d) z humánnych prekladov v slovenčine (HT_SK).

S cieľom lepšie porozumieť skúmaným textom sme texty spracovali pomocou nástrojov knižnice Stanza (Qi – Zhang – Zhang – Bolton – Manning 2020)⁵ do nasledovného korpusu (tab. 1):

Tabuľka 1: Kompozícia skúmaného korpusu

Vlastnosti	Názov vlastnosti	SMT	NMT	HT_SK	VT_EN
Čitateľnosť	Priemerná dĺžka vety (vzhľadom na slová, n)	17,215	17,120	17,835	19,263
	Priemerná dĺžka slova (vzhľadom na počet znakov)	5,615	5,696	5,810	4,997
	Počet krátkych viet ($n < 10$)	487	469	441	395
	Počet dlhých viet ($n \geq 10$)	1 551	1 434	1 462	1 508
Lexikálno-gramatické vlastnosti	Frekvencia vlastných podstatných mien	1 481	1 501	1 522	3 078
	Frekvencia podstatných mien (vrátane vlastných podstatných mien)	10 825	10 070	10 740	8 627
	Frekvencia prídavných mien	3 401	3 324	3 467	2 968
	Frekvencia prísloviek	1 098	933	966	1 667
	Frekvencia sloviac	5 763	5 198	5 287	6 473
	Frekvencia zámen	2 644	2 371	2 570	2 124
	Frekvencia častíc	793	592	782	149
	Frekvencia cudzích slov	981	841	841	-
	Frekvencia citoslovieac	1	3	3	3
	Frekvencia číslovieac	659	617	619	777
	Frekvencia predložieac a spojok	6 316	6 028	6 250	6 697
	Frekvencia interpunkcie	5 336	5 958	5 881	3547

V slovenskej lingvistiky sú známe precízne výskumy venované frekvencii slovných druhov v rôznych štýloch (najmä Mistrík 1969, 1997 a Findra 2004). Podľa J. Mistríka (1997, s. 461) je pre publicistický štýl príznačný vysoký výskyt substantív, číslovieac, skratieac, názvov a značieac. V súhre s prevahou výskytu menných slov-

⁵ Stanza je knižnica na automatické spracovanie prirodzeného jazyka v programovacom jazyku Python, ktorá bola vytvorená na Stanfordskej univerzite.

ných druhov je malý výskyt slovíes. Tieto tendencie potvrdzuje aj tab. 1, predovšetkým frekvencie podstatných mien v porovnaní s frekvenciou slovíes pri jednotlivých typoch prekladov a textov. Najvyšší počet podstatných mien (v zhode s charakterom publicistických textov) a porovnateľné frekvencie pri SMT (10 825), NMT (10 070) i humánnom preklade (10 740) by mohli poukazovať na to, že strojový preklad má najmenej problémy s identifikáciou substantív v texte, osobitne jednoznačné je to najmä v prípade vlastných podstatných mien, pri ktorých sú diferencie minimálne. Slovesá dosiahli pri SMT frekvenciu 5 763, pri NMT 5 198, čo sa viac približovalo frekvencii výskytu slovíes v HT (5 287). Podobný výsledok vidíme aj pri príslovkách (odpovedajúcich v publicistických textoch na otázky *kde, kedy, ako...*), ktorých počet pri NMT sa viac približuje k humánnemu prekladu. Naopak, v prípade podstatných mien sa frekvencia pri humánnom preklade viac približovala k SMT a nie k NMT.

4. POROVNANIE KVALITY SMT A NMT Z ANGLIČTINY DO SLOVENČINY (NA ZÁKLADE VYBRANÝCH KATEGÓRIÍ)

V nasledujúcej časti sa pokúsime na niekoľkých preložených segmentoch demonštrovať chyby, ku ktorým pri jednotlivých prekladateľských technológiách dochádzalo. Pre rozsiahlosť problematiky sa nebudeme zameriavať na všetky oblasti chybovosti strojového prekladu, ale zameriame sa len na tie, ktoré zreteľne demonštrujú rozdiely medzi analytickou angličtinou a flektívnou slovenčinou a zároveň frapantne poukazujú na rozdiely vo výsledkoch SMT a NMT.

Zamerali sme sa na dve oblasti skúmania – na oblasť gramatiky a lexiky. Keďže gramatika je sama osebe veľmi široká oblasť, s ohľadom na cieľ tohto príspevku sme si vybrali jeden z najtypickejších rozdielov medzi flektívnymi a analytickými jazykmi, a to prítomnosť, resp. neprítomnosť kategórie **mennej zhody (kongruencie)**.⁶ V oblasti lexiky sme sa zamerali najmä na oblasť **sémantickej adekvátnosti prekladu**, ktorá môže byť narušená z rôznych príčin, medzi najtypickejšie príčiny patrí najmä rozsiahla polysémia a homonymia anglických lexém. Keďže sme sa venovali prekladu komplexných segmentov, vo viacerých prípadoch poukazujeme na tom istom segmente na chyby v oblasti narušenej, resp. nerealizovanej gramatickej zhody, no zároveň sa venujeme aj otázke sémantickej adekvátnosti prekladu, ak to bolo pre analyzovanú časť relevantné.

Mennú zhodu možno považovať za jednu z konštituujujúcich kategórií flektívnych jazykov, medzi ktoré patrí aj slovenčina. Kategóriu mennej zhody majú slovné druhy adjektívneho charakteru, tzv. adjektíváliá (adjektívne zámená: *môj, moja, moje...*; činné prídavia: *čítajúci, čítajúca, čítajúce*; trpné prídavia: *preložený, prelo-*

⁶ Hoci sa v tomto príspevku budeme venovať v rámci gramatiky len mennej morfosyntaxi, typologické charakteristiky anglického a slovenského jazyka majú zásadný vplyv aj na chyby v oblasti predikativnosti vety, ako to dokazujú výsledky K. Welnitzovej (2021).

žená, preložené...; číslovky: prvý, prvá, prvé, dvojaký, dvojaká, dvojaké...) (Vaňko 2015, s. 71). Kategóriu zhody však vnímame najmä na pozadí syntagiem adjektív s gramaticky nadradenými substantívami. Z dôvodu dostatočne diferencovaných tvarov prídavných mien je ich umiestnenie vo vete pomerne voľné (Dvonč a kol. 1966, s. 54). V prípade analytického anglického jazyka je však situácia odlišná. Keďže angličtina nedokáže vyjadriť podradenosť určujúceho adjektíva voči nadradenému slovu jeho tvarom, musí podradené slovo (v našom prípade adjektívum alebo iné slovo adjektívneho rázu) stáť pred nadradeným členom. Atributívna determinácia sa v angličtine teda vyjadruje iba pozíciou prívlastku pred substantívom, nie jeho tvarom: *German media – nemecké médiá*, ale *German – Nemeč*; *rookie team – nový (nováčikovský) tím*, ale *rookie – nováčik*.

Pre strojový preklad tu teda vzniká problém, pretože pri preklade z analytického do flektívneho jazyka musí stroj detegovať niečo, čo vo východiskovom jazyku neexistuje. V rámci analýz strojovo preložených textov sme identifikovali chyby v transponovaní kongruenčných kategórií rodu, čísla a pádu (chybne mohla byť identifikovaná len jedna z týchto kategórií, dve, príp. aj všetky). Častým javom bolo však aj spolupôsobenie viacerých chýb, resp. jedna chyba mohla iniciovať výskyt inej. Početné boli napr. nesprávne slovnodruhovú transfery, teda stroj nesprávne identifikoval slovný druh. Príčinou týchto chýb bola najmä tvarová homonymia, ktorá je pre angličtinu ako analytický jazyk príznačná, porov. napr. *he repaired the car (opravil auto) – the car was repaired (auto bolo opravené)*.

Priklad č. 1:⁷

- VT: *The Paris attacks, which were claimed by Isis, are believed to have been in part prepared and coordinated in Brussels.*
- SMT: *Parižskej útoky, ktoré boli nárokované Isis, sú veril k boli čiastočne pripravené a koordinované v Bruseli.*
- PEMT: *Parižske útoky, ku ktorým sa prihlásil Isis, sa považujú za čiastočne pripravené a koordinované v Bruseli.*
- NMT: *Predpokladá sa, že parižske útoky, ktoré si vyžiadala Isis, boli čiastočne pripravené a koordinované v Bruseli.*
- DeepL: *Predpokladá sa, že parižske útoky, ku ktorým sa prihlásila Isis, boli sčasti pripravené a koordinované v Bruseli.*
- ChatGPT: *Útoky v Paríži, ktoré prebrala organizácia ISIS, sa predpokladá, že boli čiastočne pripravené a koordinované v Bruseli.*

⁷ VT – východiskový text v anglickom jazyku; SMT – štatistický strojový preklad; PEMT: posteditovaný (štatistický) strojový preklad prekladateľom; NMT – neurónový strojový preklad. Najpodstatnejšie pre porovnanie je VT, SMT a NMT. PEMT uvádzame len z dôvodu lepšej orientácie v preklade, ide o akýsi „vzorový“ preklad, resp. v nevyhnutnej miere korigovaný štatistický strojový preklad. Vzhľadom na to, že SMT aj NMT boli preložené rovnakou službou (Google Prekladač), hoci v rôznych časových úsekoch, na porovnanie uvádzame aj preklady v dvoch ďalších voľne dostupných službách automatického prekladu, a to DeepL a ChatGPT.

Z príkladu č. 1 je zrejmé, že SMT mal problémy s identifikovaním správneho tvaru adjektíva *parížske*, a to napriek tomu, že plurálový tvar nadradeného substantíva *útoky (attacks)* identifikoval správne. Naproti tomu NMT s identifikáciou správneho tvaru určujúceho adjektíva problém nemal a správne transponoval celú determinatívnu syntagmu *parížske útoky*. Rovnakú determinatívnu syntagmu použil aj nástroj DeepL. Hoci ChatGPT zmenil determinatívnu syntagmu so zhodným prívlastkom na determinatívnu syntagmu s nezhodným atribútom (*útoky v Paríži*), sémanticky i gramaticky ide v slovenčine stále o korektnú konštrukciu.

V súčasnosti sa najčastejšie manuálne hodnotenie kvality strojového prekladu realizuje podľa osi adekvátnosť a plynulosť, kde sa adekvátnosť (presnosť) chápe ako miera, do akej strojový preklad zachytáva význam východiskového textu, a plynulosť (zrozumiteľnosť) ako miera, do akej je strojový preklad „dobrým“ príkladom (textom) cieľového jazyka. Môžeme skonštatovať, že z hľadiska **plynulosti** je NMT na veľmi dobrej úrovni; gramatická konštrukcia vety vcelku primerane zodpovedá očakávanej konštrukcii vety v slovenčine. Najväčším problémom je však sémanticky neadekvátny preklad lexémy *claim*, resp. *claimed* ako *vyžiadať* namiesto očakávanej alternatívy *prihlásiť*. Ako problém sa tu teda pre NMT ukazuje najmä bohatá homonymia a polysémia anglických lexém. Zdanlivo sa NMT javí na prvý pohľad gramaticky plynulejší, z hľadiska sémantickej adekvátnosti tu však identifikujeme vážnejšie chyby, ako to ukázu aj ďalšie príklady. Najzásadnejšie nedostatky v prípade NMT identifikujeme skôr v oblasti **presnosti** než plynulosti (fluency). V danom preklade však za sémanticky korektný preklad lexémy *claim* nemôžeme považovať ani SMT preklad ako *nárokované*. Sémanticky nekorektný preklad tohto slova zaznamenávame aj pri ChatGPT. Naopak, DeepL aj toto sloveso preložil sémanticky korektné ako *prihlásila*. Hoci sa v PEMT uvádza tvar slovesa v mužskom rode (*prihlásil*), za nesprávny nepovažujeme ani tvar ženského rodu *prihlásila*, pokiaľ skratku *ISIS* chápeme v kontexte označenia organizácie či skupiny, nie ako skratku pre islamský štát. Napokon, všetky analyzované preklady založené na nových technológiách (NMT, DeepL, ChatGPT) uviedli prísudok v tvare ženského rodu. Z formálneho hľadiska možno ešte uviesť, že za správnejšie by sme považovali uvádzanie iniciálovej skratky *ISIS* s verzálkami, v tomto prípade však prekladače zrejme rešpektovali podobu východiskového textu (s výnimkou ChatGPT).

Príklad č. 2:

VT: *How the rookie team gets on: ...*
SMT: *Ako nováčik tím dostane na: ...*
PEMT: *Ako sa darí novému tímu: ...*
NMT: *Ako nastupuje nováčikovský tím: ...*
DeepL: *Ako sa darí tímu nováčikov: ...*
ChatGPT: *Ako sa nováčikovský tím darí:*

Z dôvodu prehľadnosti a zamerania analýzy uvádzame v príklade č. 2 len úvodnú časť preloženého segmentu. Tento príklad demonštruje, ako tvarová homonymia dokáže podmieniť vznik ďalších chýb v strojovom preklade (najmä v SMT), konkrétne v tomto prípade išlo o nesprávny slovnodruhový transfer, keď SMT lexému *rookie* transponoval ako substantívum *nováčik* namiesto očakávaného adjektíva *nový/nováčikovsky*. NMT aj v tomto prípade správne identifikoval, že ide o adjektívum. Opäť tu však zostáva problémom sémanticky nekorektný preklad lexémy *get* ako *nastupuje* namiesto vhodnejších ekvivalentov (*dostať sa* či voľnejší preklad *dať sa*). V tomto prípade teda za gramaticky korektnejší (plynulejší) považujeme síce preklad NMT, ale za sémanticky adekvátnejší by sme mohli označiť skôr preklad SMT. Rovnakú determinatívnu syntagmu identifikujeme aj pri preklade ChatGPT, hoci je výpoveď gramaticky nekorektná. V tomto prípade síce DeepL použil na rozdiel od NMT či ChatGPT determinatívnu syntagmu s nezhodným atribútom (*tím nováčikov*), ako jediný systém však dokázal preložiť celú vetu gramaticky správne, teda uviedol v korektnom tvare datívu singuláru spojenie *tímu nováčikov*. Analyzovanú determinatívnu syntagmu s nezhodným prívlastkom, ktorú systém DeepL použil, takisto považujeme za sémanticky i gramaticky korektnú, navyše v uvedenom kontexte pre slovenčinu i za „prirodzenejšiu“.

Príklad č. 3:

- VT: **Teacher supply expert** Prof John Howson, who runs recruitment website TeachVac, says he believes the poor teacher retention rate has „more to do with economics than politics“.
- SMT: **Učiteľ dodávka expert** Prof John Howson, ktorý prevádzkuje internetové stránky náboru TeachVac, hovorí, že verí, že chudobný učiteľ miera retencie má „viac čo do činenia s ekonomikou ako politika“.
- PEMT: **Odborník na získavanie učiteľov** prof. John Howson, ktorý prevádzkuje webovú lokalitu TeachVac zameranú na nábor učiteľov, hovorí, že verí, že nízka miera retencie učiteľov „viac súvisí s ekonomikou ako s politikou“.
- NMT: **Expert na dodávky učiteľov** Prof John Howson, ktorý vedie náborový web TeachVac, tvrdí, že je presvedčený, že zlá miera zadržiavania učiteľov má „viac spoločné s ekonomikou ako s politikou“.
- DeepL: **Odborník na ponuku učiteľov** profesor John Howson, ktorý prevádzkuje náborovú webovú stránku TeachVac, tvrdí, že podľa neho má slabá miera udržania učiteľov „viac spoločného s ekonomikou ako s politikou“.
- ChatGPT: **Odborník na učiteľský personál**, profesor John Howson, ktorý prevádzkuje webovú stránku na nábor učiteľov TeachVac, tvrdí, že si myslí, že nízka miera udržania učiteľov má „viac čo do činenia s ekonomikou než s politikou“.

Príklad č. 3 naznačuje, že zložené syntagmy sú problémom najmä pre SMT, ktorý v tomto prípade syntagmu *teacher supply expert* preložil doslovne ako *učiteľ dodávka expert*. Ale gramatická konštrukcia, ktorú vyprodukoval NMT, už zodpovedá očakávanému modelu *odborník/expert na získavanie učiteľov*, hoci preklad lexé-

my *supply* ako *dodávky* nemožno považovať za sémanticky korektný; v tomto prípade sa však sémantická nekorektnosť prekladu lexémy *supply* prejavila nielen pri NMT, ale aj pri SMT. Za veľký kvalitatívny posun vpred ale možno považovať korektnú realizáciu konštrukcie *expert na dodávky* (správ. *získavanie*) *učiteľov*. Rovnaký model zloženej syntagmy sa podarilo dosiahnuť i nástroju DeepL, aj keď lexému *supply* v tomto prípade preložil ako *ponuku*. Sčasti voľnejší, hoci nie úplne sémanticky nekorektný preklad uvedenej syntagmy nachádzame pri ChatGPT ako *odborník na učiteľský personál*. Pokiaľ ide o preklad lexémy *run*, pri všetkých prekladoch okrem NMT sme zaznamenali jej transponovanie do slovenčiny v podobe *prevádzkuje*. NMT danú lexému preložil ako *vedie* (*náborový web*). Hoci ani tento preklad nepovažujeme za neprijateľný, predsa však za sémanticky korektnejší v danom kontexte považujeme preklad lexémy *run* ako *prevádzkovať*.

Na viacerých predchádzajúcich príkladoch sme ukázali, že NMT priniesol významný kvalitatívny posun v oblasti plynulosti, gramatickej korektnosti prekladu, zároveň však analyzované príklady poukázali aj na výraznú slabinu tohto prekladu, ktorou je presnosť, sémantická adekvátnosť prekladu. Posledný príklad túto tendenciu rovnako dokazuje:

Príklad č. 4:

- VT: *Michel called on residents to “stay calm and cool-headed” as the investigation continued into Tuesday’s police raid.*
- SMT: *Michel vyzval obyvateľov, aby „zostať v pokoji a rozvážny“, ako vyšetrovanie pokračuje do utorkovej policajnej razii.*
- PEMT: *Po utorkovom policajnom zásahu Michel vyzval obyvateľov, aby „zostali pokojní a nepodliehali panike.“*
- NMT: *Počas vyšetrovania utorkovej policajnej razie Michel vyzval obyvateľov, aby „zostali pokojní a chladní“.*
- DeepL: *Michel vyzval obyvateľov, aby „zachovali pokoj a chladnú hlavu“, keďže vyšetrovanie utorňajšej policajnej razie pokračuje.*
- ChatGPT: *Michel vyzval obyvateľov, aby „zostali pokojní a chladnokrvní“, zatiaľ čo prebiehala vyšetrovanie utorňajšieho zásahu polície.*

Tento príklad ukazuje, že za sémanticky korektnejší preklad frázy *stay calm and cool-headed* opäť môžeme považovať výstup zo SMT (*zostať v pokoji a rozvážny*), hoci ho nemožno považovať za gramaticky korektný – v slovenskom preklade by sa žiadalo použiť určitý slovesný tvar *zostali* a správny plurálový tvar adjektíva *rozvážni*. Túto gramatickú konštrukciu dokázal opäť NMT vytvoriť, hoci so sémanticky nekorektným prekladom lexémy *cool-headed* ako *chladní*. Toto adjektívum je dokonca v správnom plurálovom tvare. Pokiaľ ide o alternatívy prekladu zloženej lexémy *cool-headed* ako *rozvážny* či *nepodliehať panike*, možno prijať aj voľnejší preklad navrhnutý v PEMT; ak by sme však uplatnili požiadavku minimalistických a nevyhnutných zásahov s cieľom upraviť text do gramaticky a sémanticky prijateľ-

nej podoby, za prijateľný preklad považujeme aj lexému *rozvážny* navrhnutú štatistickým strojovým prekladom. Napriek menším rozdielom v preklade spojenia *stay calm and cool-headed* nástrojmi DeepL a ChatGPT považujeme oba preklady za sémanticky i gramaticky korektné (*zachovali pokoj a chladnú hlavu; zostali pokojní a chladnokrvní*). Avšak vzhľadom na ďalšie konotácie adjektíva *chladnokrvný*, ktoré môže okrem významu „ktorý triezvo uvažuje, ktorý nepodlieha citom a navonok neprejavuje citové rozpoloženie, pokojný“ znamenať aj „ktorý nemá dostatok citu, súcitu, zľutovania s niekým, s niečím“ (Slovník súčasného slovenského jazyka. H – L 2011), považujeme za vhodnejší preklad DeepL ako *zachovali pokoj a chladnú hlavu*. Z hľadiska komplexného prístupu k preloženému segmentu hodnotíme preklad tejto vety nástrojom DeepL opäť ako gramaticky i sémanticky najkvalitnejší.

Porovnanie početnosti chýb v analyzovaných kategóriách medzi SMT a NMT uvádzame v tab. 2 a 3.:

Tabuľka 2: Chybovosť v kategórii menšej zhody pri SMT a NMT (kontingenčná tabuľka)⁸

SMT \ NMT	0	1	Celkovo
0	1 387	6	1 393
Stĺpec %	81,68 %	85,71 %	
Riadok %	99,57 %	0,43 %	
Počet %	81,35 %	0,35 %	81,70 %
1	311	1	312
Stĺpec %	18,32 %	14,29 %	
Riadok %	99,68 %	0,32 %	
Počet %	18,24 %	0,06 %	18,30%
Počet	1 698	7	1 705
Celkovo %	99,59 %	0,41 %	100,00 %

Po analýze chýb a porovnaní štatistického i neurónového strojového prekladu textov nášho korpusu (1 705 segmentov) sme identifikovali 311 segmentov, v ktorých neurónový strojový preklad nevykazoval a štatistický strojový preklad vykazoval chybu v zhode v determinatívnej syntagme a iba v jednom prípade chyba v zhode v determinatívnej syntagme pretrvala. Na druhej strane sme identifikovali iba 6 segmentov, v ktorých štatistický strojový preklad nevykazoval chybu, ale v neurónovom strojovom preklade práve vznikla chyba v menšej zhode v determinatívnej syntagme. Na základe výsledkov McNemarových testov (*Chi-square* = 1382,006, *df* = 1, *p* = 0,000 / *Chi-square* = 291,533, *df* = 1, *p* = 0,000) zamietame hypotézu, že

⁸ V tab. 2 znamená 0 bezchybný segment, 1 znamená chybný segment.

nie je štatisticky významný rozdiel vo výskyte chybných segmentov medzi štatistickým a neurónovým strojovým prekladom v prospech neurónového strojového prekladu. Teda neurónový strojový preklad je kvalitnejší (štatisticky významne) ako štatistický strojový preklad, pokiaľ ide o výskyt chýb v kategórii menšej zhody.

Tabuľka 3: Chybovosť v kategórii adekvátneho transferu významu slova pri SMT a NMT (kontingenčná tabuľka)⁹

SMT \ NMT	0	1	Celkovo riadkov
0	212	535	747
Stĺpec %	44,73 %	43,46 %	
Riadok %	28,38 %	71,62 %	
Počet %	12,43 %	31,38 %	43,81 %
1	262	696	958
Stĺpec %	55,27 %	56,54 %	
Riadok %	27,35 %	72,65 %	
Počet %	15,37 %	40,82 %	56,19 %
Počet	474	1231	1705
Celkovo %	27,80%	72,20%	100,00 %

Na základe výsledkov analýzy kontingencie (tab. 3) sme identifikovali 262 segmentov, v ktorých bol neurónový strojový preklad bezchybný v porovnaní so štatistickým strojovým prekladom, ktorý vykazoval chybu v adekvátnej transfere významu slova. Avšak v 535 segmentoch vznikla chyba pri neurónovom strojovom preklade, ktorá sa nenachádzala v štatistickom strojovom preklade. Na základe výsledkov McNemarových testov ($Chi-square = 256,926$, $df = 1$, $p = 0,000$ / $Chi-square = 92,828$, $df = 1$, $p = 0,000$) zamietame hypotézu, že nie je štatisticky významný rozdiel vo výskyte chybných segmentov medzi štatistickým a neurónovým strojovým prekladom v prospech štatistického strojového prekladu.

5. ZÁVER

Strojový preklad od svojho vzniku v 50. rokoch minulého storočia prešiel niekoľkými paradigmatickými posunmi, od strojového prekladu založeného na pravidlách a slovníku k strojovému prekladu založenému na štatistike a korpusoch až k strojovému prekladu založenému na neurónových sieťach. Avšak až nedávny posun k neurónovému strojovému prekladu, ktorý využíva hlboké učenie sa, sa o strojový preklad začali zaujímať nielen vedci, ale aj spoločnosť (Melby 2020; Asscher – Glikson 2021). Zvýšením úrovne kvality NMT exponenciálne narástlo jeho použí-

⁹ V tab. 3 znamená 0 bezchybný segment, 1 znamená chybný segment.

vanie nielen bežnými ľuďmi, ale aj profesionálnymi prekladateľmi a firmami. Neurónový strojový preklad je v podstate „čierna skrinka“, ktorej chýba algoritmická transparentnosť. Pri určení pravdepodobnosti výstupných prekladov využíva neurónové siete (techniky hlbokého učenia sa) a vychádza z rozsiahlych jazykových korpusov.

Kvalita strojového prekladu sa zvýšila do takej miery, že v mnohých experimentálnych štúdiách sa prišlo k záveru, že strojový preklad sa veľmi približuje k ľudskému prekladu, ba v niektorých výskumoch bol na nerozoznanie od ľudského prekladu, napr. pri preklade spravodajských textov z čínštiny do angličtiny (Hassan a kol. 2018) alebo z angličtiny do češtiny (Bojar a kol. 2018).

Analýzou uvedených prekladov sme sa snažili dokázať, že NMT je schopný korektne transponovať aj zložitejšie syntaktické konštrukcie, čím sa vytvára dojem plynulého prekladu, no výzvou pre tento systém strojového prekladu stále zostáva otázka sémantickej adekvátnosti prekladu. Tieto tendencie dokazuje aj početnosť chýb v analyzovaných kategóriách (porov. tab. 2 a 3).

Naše výsledky výskumu korešponujú s výsledkami Pánisovej – Munkovej (2021, s. 289), ktoré pri porovnávaní SMT a NMT dospeli k záveru, že v oblasti lexickej sémantiky zaznamenali približne 20-percentný nárast chybovosti NMT voči SMT, avšak na druhej strane približne 60-percentný pokles chybovosti NMT v oblastiach súvisiacich s plynulosťou prekladu.

Aj parciálna analýza vybraných príkladov v tomto príspevku dokázala, že strojový preklad prešiel značným pokrokom, ale súčasné technológie a najmä dnes často spomínaný jazykový model ChatGPT majú ešte čo vylepšovať, hlavne pokiaľ ide o syntetické flektívne jazyky. Hoci aj naše analýzy zaznamenali značný pokrok v kvalite strojového prekladu, stále nedosahuje ľudskú paritu, pokiaľ ide o preklad publicistických textov z angličtiny do slovenčiny. Možno v blízkej budúcnosti, keď jazykové modely používané na natrénovanie strojového prekladu budú mať vyššiu kvalitu, aj kvalita prekladu sa zvýši, ale to si vyžaduje rozsiahlejšiu spoluprácu medzi „strojom“ a človekom, t. j. interakciu medzi umelou a prirodzenou (ľudskou) inteligenciou.

Ak by sme chceli zodpovedať otázku, či použitie neurónových sietí je sľubná cesta v strojovom preklade z analytického jazyka do flektívnej slovenčiny, odpoveď by znela áno. Stotožňujeme sa s názorom Jaroslawa (Jareka) Kutylowského (Shrivastava – Kutylowski 2023), že neurónové siete čoskoro budú dominantné v jazykovom a prekladateľskom odvetví a generatívna umelá inteligencia bude obrovskou príležitosťou pre prekladateľa byť viac interaktívny v procese strojového prekladu aj v prípade prekladu do slovenčiny.

Literatúra

- ASSCHER, O. – GLIKSON, E. (2021): *Human evaluations of machine translation in an ethically charged situation*. *New Media & Society*. Dostupné na: <https://doi.org/10.1177/14614448211018833> (cit. 22. 8. 2023).
- BOJAR, O. – FEDERMANN, C. – FISHEL, M. – GRAHAM, Y. – HADDOW, B. – HUCK, M. – KOEHN, P. – MONZ, C. (2018): Findings of the 2018 Conference on Machine Translation (WMT18). In: *Proceedings of the Third Conference on Machine Translation (WMT)*, Volume 2: Shared Task Papers, 272 – 307. Dostupné na: <https://doi.org/10.18653/v1/W18-6401> (cit. 22. 8. 2023).
- CASTILHO, S. – DOHERTY, S. – GASPARI, F., MOORKENS, J. (2018): Approaches to Human and Machine Translation Quality Assessment. In: Moorkens, J. – Castilho, S. – Gaspari, F. – Doherty, S. (eds.): *Translation Quality Assessment. Machine Translation: Technologies and Applications*. Vol 1. Springer, Cham, 9 – 38. Dostupné na: https://doi.org/10.1007/978-3-319-91241-7_2 (cit. 22. 8. 2023).
- DVONČ, L. – HORÁK, G. – MIKO, F. – MISTRÍK, J. – ORAVEC, J. – RUŽIČKA, J. – URBANČOK, M. (1966): *Morfológia slovenského jazyka*. Bratislava: Slovenská akadémia vied.
- FINDRA, J. (2004): *Štylistika slovenčiny*. Martin: Osveta.
- HASSAN, H. – AUE, A. – CHEN, C. – CHOWDHARY, V. – CLARK, J. – FEDERMANN, C. – HUANG, X. – JUNCZYŚ-DOWMUNT, M. – LEWIS, W. – LI, M. – LIU, M. – LIU, T. – LUO, R. – MENEZES, A. – QIN, T. – SEIDE, F. – TAN, X. – TIAN, F. – WU, L. – WU, S. – XIA, Y. – ZHANG, D. – ZHANG, Z. – ZHOU, M. (2018): Achieving Human Parity on Automatic Chinese to English News Translation. In: *arXiv:1803.05567v2*. Dostupné na: <https://doi.org/10.48550/arXiv.1803.05567> (cit. 22. 8. 2023).
- JAROŠOVÁ, A. – BUZÁSSYOVÁ, K. (eds.) (2011): *Slovník súčasného slovenského jazyka. H – L*. Bratislava: Veda.
- LIHUA, Z. (2022): The Relationship between Machine Translation and Human Translation under the Influence of Artificial Intelligence Machine Translation. In: *Mobile Information Systems*. Dostupné na: <https://doi.org/10.1155/2022/9121636> (cit. 10. 10. 2022).
- MELBY, A. K. (2020): Future of machine translation: musings on weaver's memo. In: O'Hagan, M. (ed.): *The Routledge Handbook of Translation and Technology*. London: Routledge, 419 – 436.
- MISTRÍK, J. (1969): *Frekvencia slov v slovenčine*. Bratislava: SAV.
- MISTRÍK, J. (1997): *Štylistika slovenského jazyka*. 3. vyd. Bratislava: Slovenské pedagogické nakladateľstvo.
- PÁNISOVÁ, E. – MUNKOVÁ, D. (2021): Špecifiká strojového prekladu publicistických textov z anglického do slovenského jazyka. In: *Forlang: cudzie jazyky v akademickom prostredí*. Periodický zborník vedeckých príspevkov a odborných článkov z medzinárodnej vedeckej konferencie konanej 23. – 24. júna 2021. Košice: Technická univerzita, 281 – 290.
- PETRÁŠ, P. – MUNKOVÁ, D. (2019): (Nielen) lingvistický pohľad na strojový preklad (na príklade prekladov textov technickej dokumentácie z angličtiny do slovenčiny). In: *Slovenská reč*, 84/3, 258 – 287.
- QI, P. – ZHANG, Y. – ZHANG, Y. – BOLTON, J. – MANNING, C. D. (2020): Stanza: A Python Natural Language Processing Toolkit for Many Human Languages. In: *arXiv:2003.07082*. Dostupné na: <https://doi.org/10.48550/arXiv.2003.07082> (cit. 22. 8. 2023).
- SHRIVASTAVA, R. – KUTYLOWSKI, J. (2023): This German Unicorn Is Trying To Take On Google Translate And ChatGPT. In: *Forbes*. Dostupné na: <https://www.forbes.com/sites/rashishrivastava/2023/08/08/deepl-is-trying-to-take-on-google-translate-and-chatgpt/?sh=71d365702039> (cit. 22. 8. 2023). [Rozhovor s J. Kutylowským.]
- VAŇKO, J. (2015): Ohybné slovné druhy. In: Vaňko, J. – Auxová, D.: *Morfológia slovenského jazyka*. Nitra: Univerzita Konštantína Filozofa v Nitre, 30 – 96.

- VANĀKO, J. (2017): Kategoriaľny ramec pre analyzu chyb strojoveho prekladu. In: Munkova, D. – Vako, J. – Absolon, J. – Banik, T. – Benko, L. – Machova, R. – Munk, M. – Petras, P. – Welnitzova, K.: *Myľliť sa je ľudske (ale aj strojove)*. Nitra: Univerzita Kontantna Filozofa v Nitre, 83 – 100.
- WELNITZOVA, K. (2021): Post-editing as a 21st century translator’s skill. In: Chova, L. G. – Martinez, A. L. – Torres, I. (eds.): *EDULEARN21. 13th International Conference on Education and New Learning Technologies*, Barcelona, 5th – 6th of July, 2021. Vol. 13. Barcelona: IATED. Dostupne na: 10.21125/edulearn.2021, 7319 – 7325 (cit. 22. 8. 2023).

Internetove zdroje

- ^[1] <https://www.statmt.org/europarl/> (cit. 22. 8. 2023).
- ^[2] <https://www.linguee.com/> (cit. 22. 8. 2023).
- ^[3] <https://revolutionized.com/deepl-translator-vs-google-translate/> (cit. 22. 8. 2023).
- ^[4] <https://www.deepl.com/en/blog/how-does-deepl-work> (cit. 22. 8. 2023).
- ^[5] <https://openai.com/blog/chatgpt> (cit. 22. 8. 2023).
- ^[6] <https://blog.pangeanic.com/ai-applied-to-mt-at-fitur-2021> (cit. 10. 10. 2022).
- ^[7] <https://webgate.ec.europa.eu/etranslation/public/welcome.html> (cit. 10. 10. 2022).
- ^[8] <https://greatcontent.com/machine-ai-translation-tools/#introduction> (cit. 12. 10. 2022).
- ^[9] <https://www.systransoft.com/blog/how-does-neural-machine-translation-work/> (cit. 12. 10. 2022).