

PLIN041 Vývoj počítačové lingvistiky

Strojová lingvistika

Strojový překlad

Mgr. Dana Hlaváčková, Ph.D.

40.–70. léta 20. století

Strojová lingvistika

- praktická aplikace *kvantitativní* a *algebraické* lingvistiky
- nárůst množství informací
- snaha o automatické zpracování informací a textů
- **uložení a opětovné nalezení informace** – bibliografické údaje, kartotéky, knihovnické automatizované systémy – klasifikace, indexování
- **informace o obsahu** – získávání informací (Information Retrieval), terminologie, klíčová slova, sestavování konkordancí
- práce s informacemi ve dvojkové soustavě – je možné zakódovat jazykové kategorie, které mají binární povahu
- algoritmický popis jazyka
- *Názor lingvisty na automatické zpracování jazykových údajů (P. Garvin, 1962)*

Strojový překlad (od 50. let 20. st.)

- první písemná zmínka 1947 – dopis W. Weaveru N. Wienerovi:
„... I have wondered if it were unthinkable to design a computer which could translate.“
„This is really written in English, but it has been coded in some strange symbols“ (při pohledu na článek v ruštině, kryptografie)
1949 – Weaver – memorandum *Translation*
1952 – *The first machine translation conference* (MIT, Bar-Hillel)
1954 – *Mechanical Translation* (journal)
1955 – *Machine Translation of Languages: Fourteen Essays*
 - strojový překlad je záležitost kryptografie
 - snaha o formalizaci jazyka pro strojové zpracování, vytvoření *převodního jazyka* = formalizace významové struktury vět (nevyřešeno)

Warren Weaver 1894–1978

- americký vědec, matematik, „pionýr“ strojového překladu, organizátor vědy
- vystudoval univerzitu ve Wisconsinu, profesor matematiky v Kalifornii
- sloužil v 1. sv. v. u letecké služby
- 1932–1955 byl ředitelem oddělení přírodních věd **Rockefellerovy nadace**, zal. 1913 (Division of Natural Sciences Rockefeller Foundation), přidělování grantů v přírodních vědách
- za 2. sv. v. – řídil operace matematiků, zabýval se počítacími stroji a kryptografií
- iniciátor strojového překladu
- nadační činnost – podpora řady vědeckých projektů
- sběratel *Alenky v říši divů* (v r. 1964 – 160 verzí ve 42 jazycích)

Strojový překlad (pol. 50. – poč. 60. let)

1) nadšení a velké investice

- převod textu ze vstupního jazyka (analýza) do výstupního jazyka (syntéza)
- motivace – studená válka, narůstající počet textů v různých jazycích
- vysoká chybovost strojových překladů
 - malý rozsah paměti počítačů
 - překlad slovo za slovo (bez znalosti syntaxe)
 - vliv mimojazykových skutečností
- hledání *univerzálního převodního jazyka* – symbolická konstrukce popisující významovou strukturu věty
 - problém s formalizací významů
- pouze jednosměrné překlady z jednoho jazyka do druhého (často mezi angličtinou a ruštinou)

Georgetown-IBM experiment

- 7. 1. 1954, v centrále IBM v New Yorku, počítač IBM 701
- Cuthbert Hurd – ředitel Applied Sciences Division v IBM
- Peter Sheridan – programátor IBM
- Léon Dostert – za 2. sv. v. tlumočník generála Eisenhowera, po válce – návrh simultánního překladu (sluchátka) během Norimberského procesu
- Paul Garvin – lingvista (pův. Čech)
- Institute of Languages and Linguistics Georgetown University
 - 49 vět z ruštiny do angličtiny
 - organická chemie, obecné věty
 - 137 lexikálních jednotek (kmeny a koncovky)
 - 6 gramatických pravidel

FACHTESTVO	UGLYA	OPRYCDOVYI AYETSYA	KALORYIVOSTJYU
III I	I I	III I I I I	I I
I I I I	III I	I I I I I I I I	I III II I
I III IIIII I IIIII I I I I I III IIIII	I I II IIIII	I I II IIIII	I I II IIIII

This card is punched with a sample Russian language sentence (as interpreted at the top) in standard IBM punched-card code. It is then accepted by the 701, converted into its own binary language and translated by means of stored dictionary and operational syntactical programs into the English language equivalent which is then printed.

II	I	I I I I I I	I I

THE QUALITY CALORY CONTENT	OF	COAL	IS DETERMINED	BY
-------------------------------	----	------	---------------	----

Specimen punched card and below a strip with translation, printed within a few seconds

Strojový překlad (1. fáze)

- Erwin Reifler (1903–1965) University of Washington, Far Eastern Department
- původem Rakušan, profesor čínštiny, „pionýr“ strojového překladu, 1932–1947 Čína, Hong Kong, Japonsko (studium čínských znaků)
- 1948 článek *The Chinese Language in the Light of Comparative Semantics* – četl Weaver a poslal Reiflerovi své memorandum
- nadření pro MT
- 1951 série článků *Studies in Mechanical Translation*
- The Machine Translation Project, sponzorován letectvem USA, angličtina – ruština, angličtina – čínština

Strojový překlad (pol. 60. – poč. 70. let)

2) rozčarování

- ALPAC (Automatic Language Processing Advisory Committee), výbor ustanoven 1964 (7 vědců) – zhodnocení pokroku ve strojovém překladu
- zpráva [ALPAC z r. 1966](#), velká skepse k MT, doporučení používat počítače v překladu jen jako praktickou pomůcku a budovat elektronické slovníky
- velké investice a zklamání
- zrušení investic i výzkumu
- soustředění pozornosti na budování slovníků a výzkum jazyka (gramatika, sémantika)
- později se vyplatil bližší výzkum jazyků

Strojový překlad (70. a 80. léta)

3) umírněný optimismus a částečné úspěchy

- do popředí se dostává Kanada, Francie, SSSR, Japonsko
- **Kanada**, Montreal 1975 – systém **TAUM-METEO** (autor John Chandioux)
 - první automatický systém
 - překlad anglických meteorologických zpráv do francouzštiny
 - jednoduchá slovní zásoba i gramatika, 10–20 % svěřeno překladateli, jazyk Q, cca 1 000 slov/min
- **Francie**, Grenoble (Bernard Vauquois) – skupina GETA, překlady z ruštiny do francouzštiny, jazyk ALGOL
- **Japonsko** – univerzity Tokio, Osaka, firma Hitachi
 - **Makoto Nagao** – průkopník NLP a MT v Japonsku
 - úspěšný překlad mezi angličtinou a japonštinou
 - example-based MT, rozdělení na fráze

Yehoshua Bar-Hillel

- 1915 Vídeň – 1975 Jeruzalém
- izraelský filozof, logik, matematik, lingvista
- předmět zájmu – algebraická lingvistika, strojový překlad, získávání informací, logické aspekty přirozených jazyků
- 1933 emigroval do Palestiny, žil v kibucu, usadil se v Jeruzalémě
- za 2. sv. v. bojoval v Židovské brigádě britské armády, potom v Izraelské válce o nezávislost (přišel o oko)
- Hebrew University v Jeruzalémě střídá s Research Laboratory of Electronic na MIT (strojový překlad)

Yehoshua Bar-Hillel

- snaha o sblížení logiky a lingvistiky (sémantiky)
- spolupráce s R. Carnapem, formální popis sémantiky, článek *Semantic Information*, 1953
- kategoriální gramatika (vliv Chomského)
- od poč. 50. let ovlivněn kybernetikou (N. Wiener), práce na MIT v oblasti strojového překladu
- 1952 vede první konferenci o strojovém překladu
- **velké nadšení**, ale zdůrazňuje podíl lidské práce při překladech
- konec 50. let – **skepse a silná kritika** využití statistických metod a hledání mezijazyka, ani rozsáhlá data nevyřeší všechny víceznačnosti

Yehoshua Bar-Hillel

- 1960 zpráva sponzorům a vládě USA o neúspěšnosti MT (bývala citována jako důkaz nemožnosti MT)
- *Language and Information*, 1964
- *Aspects of Language*, 1970
- (vnučka Gili Bar-Hillel přeložila Harryho Pottera do hebrejštiny)

Andrew Donald Booth

- 1918–2009
- matematický fyzik, elektroinženýr,
- za 2. sv. v. – krystalografie (výbušnin)
 - mechanické a elektromechanické kalkulátory (pro triviální aritmetické výpočty)
- po 2. sv. v. – 4 skupiny v Británii – budování počítačů
- Booth – Birkbeck College University of London (musí být dost levný, levné komponenty)
- 1946 Rockefellerova nadace – cesta po USA za návrháři prvních počítačů (John von Neumann, Princeton) – návrh počítače s von Neumanovou architekturou
- návrh paměti – **magnetický buben**
- 1947 setkání s Weaverem – financování výzkumu krystalografie (electronic computer), strojový překlad
- počítač Automatic Relay Computer (ARC)