

PLIN041 Vývoj počítačové lingvistiky

Další aplikace matematiky v lingvistice
Teorie komunikace a teorie informace

Mgr. Dana Hlaváčková, Ph.D.

40.–70. léta 20. století

Glottochronologie

- nová jazykovědná disciplína, lexikální statistika (lexikostatistika), na poč. 50. let v USA
- v r. 1950 ji navrhl a popsal **Morris Swadesh**, americký lingvista, historicko-srovnávací lingvistika (1909–1967) – indiánské a eskymácké jazyky a dialekty
- inspirace radiokarbonovou metodou v chemii – rozpad radioaktivních jader uhlíku (poločas rozpadu)
- zjišťuje se původ jazyka a **doba rozpadu jazyka** na dva či více moderních jazyků
- příbuzenské jazykové vztahy se měří na základě změn v **základní slovní zásobě**

Glottochronologie

- jádro slovní zásoby, cca 200 slov označujících základní skutečnosti – *matka, otec, muž, žena, zvíře, malý, velký atd.* (*Swadesh list*)
- u dvou různých jazyků se porovnává 100 základních výrazů a měří se jejich shoda či rozrůzněnost v průběhu času
- na základě procenta shodných a různých dvojic se stanovuje **index rychlosti**, s jakou slova mizí z jádra slovní zásoby
- čas, kdy došlo k rozrůznění slovní zásoby – **časová hloubka** (podíl logaritmu procenta shodných dvojic a indexu rychlosti)

Glottochronologie

- pozitivní ohlasy u jazyků s mladší historií
- kritika indoevropéistů – jazyky s dlouhou historií, nesoulad výsledků
 - subjektivní výběr jádra slovní zásoby
 - rozpad jádra neprobíhá konstantní rychlostí
 - podíl externích vlivů – převratná období, styk s jinými jazyky apod.
- použili **M. Čejka** a **A. Lamprecht** – rozpad praslovanské jednoty (větev jižní, východní a západní) – 8.–11. st. (s vrcholem ve st. 10.), ověřovali i tradičními metodami

Stylometrie

- frekvenční výzkumy v oblasti stylistiky – frekvence slov a gramatických kategorií v jednotlivých stylistických rovinách
- statistické charakteristiky stylu jednotlivých autorů – **určování autorství**
- typické a unikátní znaky autora, lze vyčíslit – otisk autora, **stylom**
- spory o autorství – Shakespeare, Jan Neruda, Rukopis královédvorský a zelenohorský
- např. Kriminalistický ústav Policie ČR – grafická analýza, forenzní lingvistika
- dnes s využitím strojového učení

Teorie komunikace a informace

- matematika – první počítače, kybernetika, strojový překlad
- 40./50. léta nové vědní obory v matematice, výzkum přenosu informace, souvislost se vznikem kybernetiky
- **Claude Elwood Shannon** (angl. matematik), **Warren Weaver** (am. matematik, fyzik) – **The Mathematical Theory of Communication**, 1949, určeno matematikům
- **Charles Francis Hockett** (am. strukturalista) – **Review of Shannon & Weaver**, Language, 1953, recenze, přiblížil dílo lingvistům
- **Norbert Wiener** – zformuloval teorii informace nezávisle na Shannonovi a Weaverovi, zakladatel **kybernetiky**

Norbert Wiener

- 1894–1964, americký matematik a filozof, zakladatel kybernetiky
- *Cybernetics or the Control and Communication in the Animal and the Machine*, 1948 (Kybernetika aneb Řízení a sdělování u organismů a strojů)
- v 11 letech začal studovat na vysoké škole matematiku, v 15 letech bc. titul, vystudoval filozofii, ale disertace (v 17 letech) souvisela s matematickou logikou, Harvard (zoologie), Cambridge
- učil filozofii na Harvardu a matematiku na MIT, pracoval v oblasti balistiky
- teorie pravděpodobnosti, náhodné procesy a šum
- *u studentů znám chabým způsobem přednášení, vtipy a roztržitostí*
- dodnes je udělována Wienerova cena za aplikovanou matematiku


Norbert Wiener

- snažil se vstoupit do armády za 1. sv. v. (odmítán kvůli slabému zraku), přijat až na konci války jako prostý voják
- účastnil se prací v oblasti balistiky
- za 2. sv. v. – střely na velkou vzdálenost
 - automat (servomechanismus)
 - 1) zasáhnout cíl, 2) odpovědět na otázku (zpětná vazba)
- na konci války – 1. radarem řízená střela (navádění během letu), pak se věnoval automatům (informace si pamatují)
- zformuloval teorii informace nezávisle na Shanonovi a Weaverovi
- po válce – kybernetika

Norbert Wiener

- kybernetika zkoumá stroje i živé organismy (pomezí disciplína)
- éra kybernetických strojů, počítače, analogie s lidským mozkiem (zpětná vazba na podněty z okolí u živých organismů i strojů)
- vynutila si teorii informace
- vliv – informatika, umělá inteligence, neuronové sítě
- na východě kybernetika nejdříve buržoazní pavěda – přijata na konci 50. let

Stručný filosofický slovník, Státní nakladatelství politické literatury, 1955



je makroobjekt. Idealisté tvrdí, že podle toho, jakých přístrojů použijeme, má mikročástice buď ty, nebo ony vlastnosti (navzájem „komplementární“). Přístroj prý „vytváří“ stav objektu. Idealisté dospívají k popírání přičinnosti v mikroprocesech, k uznávání „svobodné vůle“ elektronu a k jiné mystice. Tato tvrzení doprovázejí reakčním závěrem o universalitě kvantové mechaniky, o tom, že hlubší theoretické poznání mikroprocesů je nemožné. Skutečný obsah kvantové mechaniky tyto smyšlenky idealistů, jež jsou vědě škodlivé, vyvrací. Pohyb mikroobjektů je určován objektivními fyzikálními podmínkami, v nichž mikroobjekty existují nezávisle na pozorovateli, a ne makropřístrojem, který pouze odhaluje stav pohybu částic. Pojmy kvantové mechaniky skutečně adekvátně vyjadřují specifický charakter zákonů pohybu mikroobjektů a zdaleka nejsou pouze „makroskopické“. Sovětští vědci ukázali naprostou bezpodstatnost a reakčnost subjektivistického výkladu kvantové mechaniky. Sovětští fyzikové však musí ještě rozřešit úkol, jak kvantovou mechaniku důsledně materialisticky vyložit, dále ji zobecňovat a rozvíjet.

KYBERNETIKA (ze starořeckého slova s významem řídicí) — reakční pavěda, která vznikla v USA po druhé světové válce a značně se rozšířila i v jiných kapitalistických zemích; forma soudobého mechanicismu. Stoupenci kybernetiky ji definují jako universální vědu o spojích a komunikacích v technice, o živých organizmech a o společenském životě, o „všeobecné organizaci“ a řízení všech procesů v přírodě a ve společnosti. Kybernetika tak ztotožňuje mechanické, biologické a sociální vzájemné souvislosti a zákonitosti. Kybernetika jako každá mechanistická teorie popírá kvalitativní specifickou zákonitost různých forem existence a vývoje hmoty a redukuje je na mechanické

zákonitosti. Kybernetika vznikla na základě moderního rozvoje elektroniky, zejména nejnovějších mechanisovaných počítačích strojů, automatiky a telemechaniky. Na rozdíl od starého mechanicismu 17.—18. století nezkoumá kybernetika psychofysiologické a sociální jevy analogicky s nejjednoduššími mechanismy, ale s elektronovými stroji a přístroji; ztotožňuje práci mozku s prací počítačového stroje a společenský život se systémem elektro- a radiokomunikací. Svou podstatou směruje kybernetika proti materialistické dialektice, proti moderní vědecké fyziologii, kterou založil I. P. Pavlov (viz), a proti marxistickému, vědeckému pojetí zákonů společenského života. Tato mechanistická metafyzická pavěda se výtečně smíší s idealismem ve filosofii, psychologii a sociologii.

Kybernetika jasně vyjadřuje jeden z hlavních rysů buržoasního světového názoru, jeho nelidskost a snahu přeměnit pracující v součástku stroje, ve výrobní nástroj a nástroj války. Zároveň je pro kybernetiku charakteristická imperialistická utopie, podle níž má být živý, myslící člověk, jenž bojuje za své zájmy, nahrazen ve výrobě i ve válce strojem. Podněcovatelé nové světové války využívají kybernetiky pro své špinavé praktické zájmy. Pod rouškou propagandy kybernetiky jsou v imperialistických zemích badatelé z nejrůznějších oborů zatahováni do přípravy nových prostředků masového vyhlazování lidí — elektronové, telemechanické a automatické zbraně, jejíž konstrukce a výroba se rozrostly na obrovské odvětví válečného průmyslu kapitalistických zemí. Kybernetika je tedy nejen ideologickou zbraní imperialistické reakce, ale i prostředkem k uskutečňování jejich agresivních válečných plánů.

KYRIKOVÉ — starořecká filosofická (ethická) škola, kterou založil v Athénách

ve 4. století před n. l. Antisthenes (kolem 435—370 před n. l.). V názorech této školy se odráželo smýšlení demokratických vrstev, které byly zbídačeny a přivedeny na mizinu po peloponéské válce. Za základ štěstí a blaženosti pokládali kynické co největší nezávislost na vnějších podmínkách života, pohrdání společenskými ustanoveními a konvencí, omezení svých potřeb a návrat k „přírodnímu stavu“. Nejznámějším představitelem ky-

niků byl Diogenes ze Sinope (kolem 404—323 před n. l.).

KYRENAIKOVÉ — reakční starořecká filosofická (ethická) škola, kterou založil v 5. stol. před n. l. v Kyreně (sev. Afrika) Aristippos (5.—4. stol. před n. l.) a jež vyjadřovala ideologii horních vrstev podmiňkách života, pohrdání společenské existencí, proklamaci kyrenaikové dosažení maxima smyslových rozkoší. Osobní zájmy stavěli nad zájmy společenské.


Claude Elwood Shannon

- americký matematik, elektroinženýr, kryptograf, „otec informačního věku“ (1916–2001)
- již v dětství nadání na matematiku a elektrotechniku (dálkově řízený model člunu, bezdrátový telegraf)
- MIT (návrh logických obvodů), stáž na Princetonu (setkání s významnými vědci – A. Einstein, J. von Neumann)

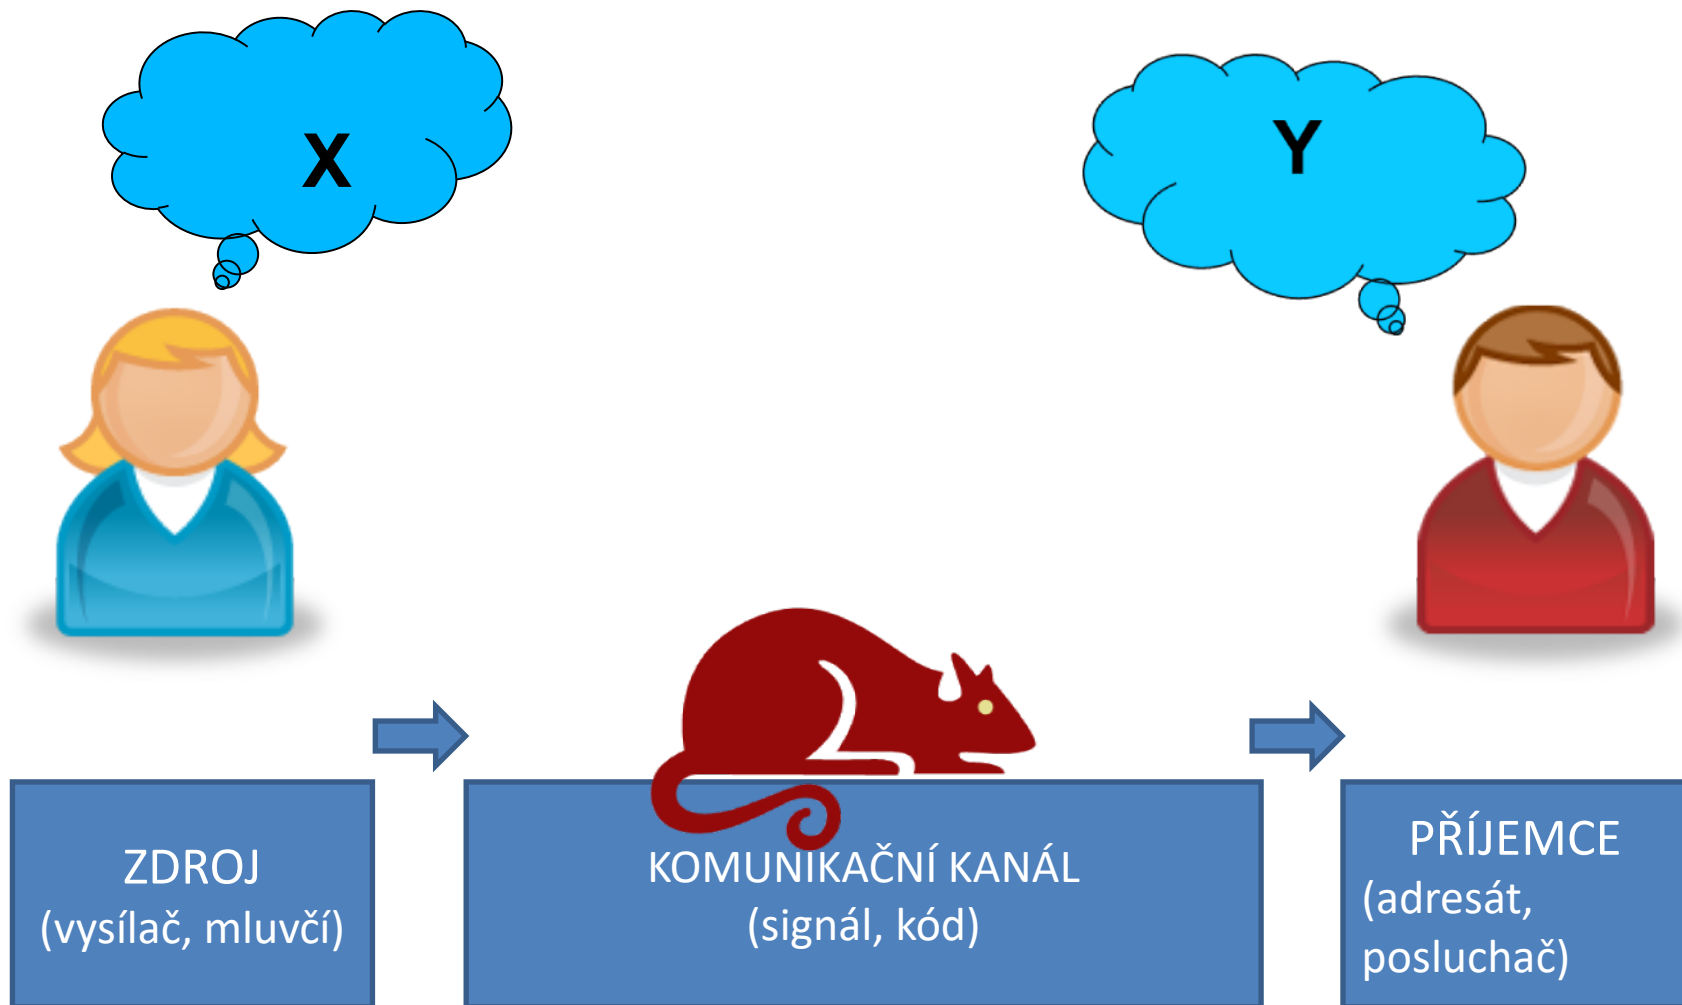
Claude Elwood Shannon

- 2. sv. v. – Bellovy laboratoře (zal. 1880 Alexander Graham Bell, dnes v New Jersey, vlastní Nokia)
- kryptografie, setkání s A. Turingem, přenos signálu a šumu – vyústilo v teorii informace
- **Prediction and Entropy of Printed English**, 1951
- vynálezy, např. Shannonova myš (učící se mechanismus, počátek AI)

Model jazykové komunikace



Komunikační šum



Teorie informace

- mluvčí – myšlenky → zvukový signál
- příjemce – na základě dosud dekódované výpovědi odhaduje další část (pravděpodobnost, Markovův proces)
- množství informace se dá měřit – **entropie** – *průměrné množství informace připadající na jeden komunikační znak*
- entropie je tím větší, čím je znak méně předvídatelný – **předvídatelnost** (predictability) – míra pravděpodobnosti, s jakou příjemce odhadne další část výpovědi

Teorie informace

- nulová entropie = **redundance**, spolehlivost přenosu x šum
- polemika, výhrady
 - vztah entropie a frekvence (nižší frekvence vyšší entropie)
 - míra informace je individuální – zkušenost, vzdělání, věk
- jednotka množství informace – **bit** (binary digit), binární opozice 0/1, binarismus v jazykovědě (již ve strukturalismu)
- 8 bitů = 1 byte

Teorie informace

- teorie informace – kybernetika – strojová lingvistika – strojový překlad
- český sborník **Teorie informace a jazykověda**, 1964 (překlady zásadních článků z této oblasti)
- **Roland Lvovič Dobrušin** (ruský matematik) – **Matematické metody v lingvistice**, 1961 – využití matematických metod pro popis lingvistických jevů, zdokonalení strojového překladu
- **Warren Plath** (americký lingvista a matematik, Harvard) – **Matematická lingvistika**, 1961 – přehled dosavadního vývoje, statistické metody při určování autorství a příbuznosti jazyků

Teorie informace

- **C. E. Shannon** – **Predikace a entropie tištěné angličtiny**, 1951, metoda odhadu entropie a redundance, využití teorie informace ve zpracování přirozeného jazyka
- **V. V. Ivanov, S. K. Šaumjan** (přední sovětský strukturalista) – **Lingvistické problémy kybernetiky a strukturní lingvistika**, 1961, (*Kibernetiku na službu kommunizmu*)

Teorie informace

- **Benoît Mandelbrot** – **Komunikace a formální struktura textů**, 1954, vliv fyzikálních a fyziologických podmínek na komunikaci, francouzský matematik, zakladatel fraktální geometrie
- **Vitold Belevitch** – **Teorie informace a lingvistická statistika**, 1956, vztah délky slova a množství informace, na ideálním umělém jazyce a na angličtině; belgický matematik ruského původu
- **Yehoshua Bar-Hillel** (izraelský filozof, matematik, lingvista), **Rudolf Carnap** (německý filozof, matematik, logik; novopozitivismus, teorie vědy) – **Sémantická informace**, 1953, teorie sémantické informace, důležitý je význam informace; strojový překlad

Teorie informace

- **Paul L. Garvin** – **Stupně začlenění počítačů do lingvistického výzkumu**, 1962, strojový překlad; americký lingvista (původem Čech), sociolingvista, antropologická lingvistika, 1990 čestný doktorát MU
- **S. M. Lamb** – **Číslicový počítač jako pomocník v lingvistice**, 1961, IBM 650, IBM 704 univerzity v USA (*MIT, Michigan, Washington, Berkeley, Los Angeles, Harvard, Pennsylvania, Severní Karolina*), nájem 45 tis. dolarů měs., 1 min 6 dolarů