

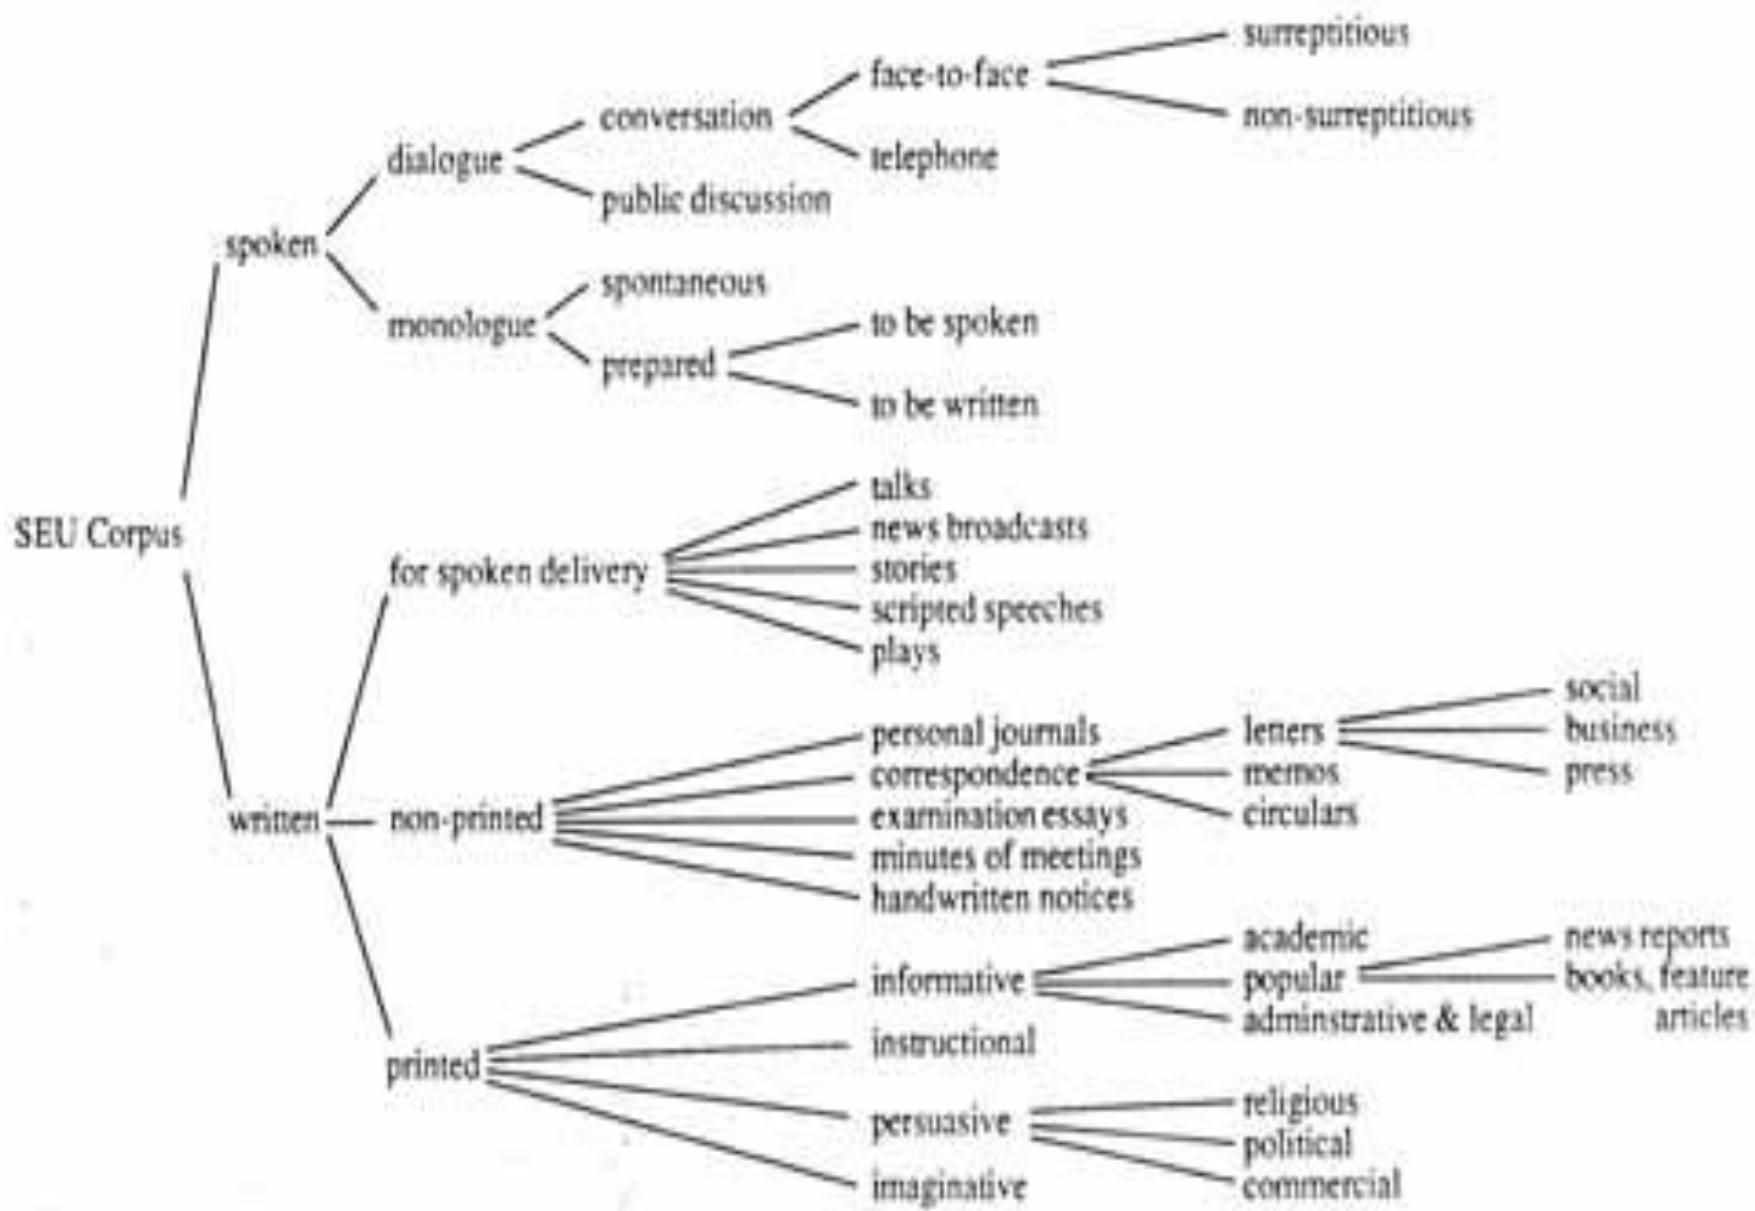
# PLIN041 Vývoj počítačové lingvistiky

Korpusová lingvistika  
od 70. let 20. st.

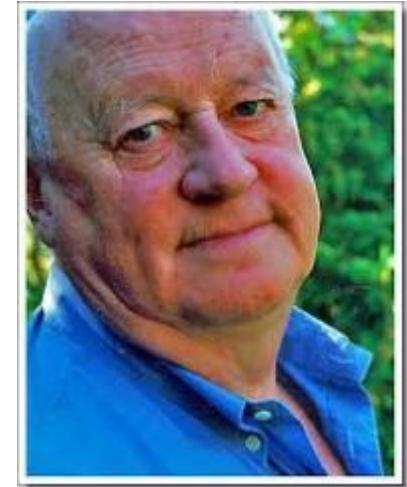
Mgr. Dana Hlaváčková, Ph.D.

# Korpusová lingvistika

- **Jan Svartvik** (1931), Sidney Greenbaum, R. Quirk, K. Hofland
- ***The London-Lund Corpus of Spoken English (LLC)***
- 1. počítačový korpus mluveného jazyka (magnetické pásky)
- spojení dvou projektů
  - **Survey of Spoken English (SSE)**, Jan Svartvik, Lund University, 1975 jako sesterský projekt SEU
    - 87 textů mluvené angličtiny (britská angličtina vzdělaných mluvčích)
    - **SEU** – 13 textů mluvené angličtiny
- celkem 100 přepisů nahrávek, 500 tisíc slov, zveřejněn až 1980
  - fonetická transkripce, značeny prozodické vlastnosti
  - někteří mluvčí o nahrávání nevěděli (spontánní projev)



# Jan Svartvik (1931)



- švédský lingvista (anglistika)
- studium na univerzitě v Uppsale, stáže na Brown University, UCL a dalších univerzitách
- 1959–60 na University of Durham u R. Quirka
- profesor angličtiny na univerzitě v **Lundu** (1970–1995)
- přední představitel korpusové lingvistiky, člen **Gang of Four** (**1961–64 SEU na UCL**)
- ve švédské lingvistice měl text ústřední postavení, jako nerodilý mluvčí nemohl využívat introspekce (důvod, proč se věnoval korpusové lingvistice)
- členství a předsednictví v mnoha vědeckých organizacích ve Švédsku i ve světě
- čestný doktorát z univerzity v Bergenu a z MU (1998, 1. Švéd v historii MU)
- spolupráce s českým lingvistou Janem Firbasem
- spolupráce s katedrami anglistiky FF a PedF MU

# Jan Svartvik

- pojmenoval nový směr – **forenzní lingvistika** (forensic linguistics)
  - *The Evans Statements: A Case for Forensic Linguistics*, 1968
  - rozbor tvrzení T. J. Evanse falešně obviněného a odsouzeného za vraždu manželky a dcery (1950)
  - na základě kvalitativní a kvantitativní analýzy předkládá pochybnosti o autorství a pravosti tvrzení
- *A Grammar of Contemporary English* (1972) – v té době Svartvik v Lundu, komunikace na dálku
- *A Comprehensive Grammar of the English Language* (1985)
- *A Life in Linguistics* (2005) – vzpomínky
- *English – One Tongue, Many Voices*, s G. Leechem (2006)

# Propojení lexikografie s korpusovou lingvistikou

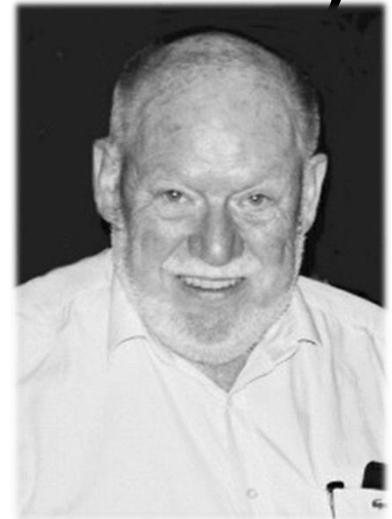
- **COBUILD** – Collins Birmingham University International Language Database, britské výzkumné centrum na University of Birmingham, od r. 1980 založeno vydavatelstvím Collins (dnes HarperCollins Publishers), na počátku vedl profesor **John Sinclair** (1933–2007)
- cílem vydání slovníku pro výuku angličtiny
- korpus **Birmingham Collection of English Text** (BCE), 1980, jako první využil OCR
  - Centre for Corpus Research University of Birmingham (od 70. let)
  - 20 mil. slov, hlavně psaná britská angličtina
  - jiná struktura než první korpusy (noviny, brožury, letáky, knihy, časopisy, korespondence), oproti LOB vyloučena poezie a drama

# Propojení lexikografie s korpusovou lingvistikou

- ***Collins COBUILD English Language Dictionary***, 1987, J. Sinclair
  - pro výuku angličtiny jako cizího jazyka
  - první slovník založený na současné, běžně užívané angličtině
- **Bank of English (BoE)**, 650 mil. slov (na poč. 90. let 200 tis.), mluvená i psaná angličtina, pro výuku angličtiny, označkován
  - dnes součástí ***Collins Corpus*** – 4,5 mld., stále se rozrůstá

# John McHardy Sinclair (1933–2007)

- britský lingvista (původem Skot)
- studoval na univerzitě v Edinburghu
- profesor moderní angličtiny –  
**Birmingham University** (1965–2000)
- jako emeritní profesor stále publikoval
- oblasti zájmu:
  - průkopník **analýzy diskurzu**
  - ***idiom principle*** (v komunikaci používáme předpřipravené konstrukce frází)
  - *Towards the Analysis of Discourse*, 1975
  - **lexikografie** – kolokace, **korpusová lingvistika**, výuka angličtiny



# John Sinclair

- *Corpus, Concordance, Collocation* (Oxford University Press, 1991)
- *Reading Concordances* (2003)
- *Trust the Text* (2004)
- 5 dětí, druhá žena *Elena Tognini-Bonelli*
  - italská anglistka, korpusová lingvistka, působí na univerzitě v Sieně (Toskánsko)
- založil asociaci *Tuscan Word Centre*, Certosa di Pontignano, výzkumné centrum korpusové lingvistiky

# Korpusy – Německo, Francie

- **Deutsches Referenzkorpus** (DeReKo), 1964, (*Mannheim corpora, IDS corpora, COSMAS corpora*), Institut für Deutsche Sprache
  - dnes 29 mld. slov (největší na světě)
  - texty cca od r. 1950
  - nevyvážený
- **LIMAS** (Linguistik und Maschinelle Sprachbearbeitung), 1970, Universität Bonn
  - německá varianta Brown Corpus – 500 textů, 15 kategorií, 1 mil. slov, texty z let 1969–70
- **Frantext** – databáze literárních textů ve francouzštině, od 10. do 21. st., (word, lemma, phrase), 500 děl, metainformace o textech

# British National Corpus (1991–1994)

- 100 mil. slov, vyvážený korpus (široké spektrum textů)
- vzorky – 45 tis. slov od jednoho autora
- **psaná (90 %) i mluvená (10 %) angličtina** (ortografická transkripce)
- *BNC World Edition*, 2001 (metainformace)
- poslední *BNC XML Edition* z r. 2007, jinak se korpus nemění (původně v SGML)
- značkování (PoS) – Lancaster University (Geoffrey Leech, Roger Garside a Tony McEnery)
- zaštítuje *BNC Consortium* (Oxford, Lancaster, nakladatelství, firmy, akademie, knihovna apod.)
- subkorpusy
  - **BNC Sampler** (1 mil. psaný, 1 mil. mluvený)
  - **BNC Baby** (4 milionové vzorky ze čtyř různých žánrů)

# Lidé kolem BNC

- Geoffrey Leech – *100 Million Word of English* (English Today, 1993)
- Tony McEnery, Andrew Wilson – *Corpus Linguistics: An Introduction* (Oxford University Press, 2001)
- Paul Baker, Lancaster University
- Sue Atkins, Jeremy Clear, Nicholas Ostler – *Corpus Design Criteria* (Literary and Linguistic Computing, 1992)
- Michael Rundell (Lexicography MasterClass)

# První korpusy

- **Brown Corpus**, 1963–1964 (Kučera, Francis)
- **Lancaster-Oslo/Bergen Corpus (LOB)**, 1970–1978 (Leech, Johansson)
- korpus a pracoviště **The Survey of English Usage (SEU)**, 1959, 1985 (Quirk, Gang of Four)
- **The London-Lund Corpus of Spoken English (LLC)**, 1980 (Svartvik, Greenbaum, Quirk, Hofland)
- **Birmingham Collection of English Text**, 1980 (John Sinclair)
- **International Corpus of English**, 1990 (Greenbaum)
- **Bank of English (BoE)**, poč. 90. let (John Sinclair)
- **British National Corpus**, 1994