



Semantics, Discourse and Machine Translation (语义、语篇和机器翻译)

张民，苏州大学

CIPSC战略研讨会，贵阳，2014年4月18日



養天地正氣
法古今完人
萬世請留名



● CIP的发展战略

○ 基于多层次篇章语义的机器翻译

CIP发展战略



- 一个国家的科学的研究和这个国家的发展状况、历史、文化、政治、经济等等密切相关
.....
- 我们每个人都在辛苦并快乐地工作着...
- 科学研究:
 - 原创性、基础研究、核心技术、影响力

- 未来十年中文信息处理的主要着眼点和着力点应该在哪里?
 - 中文语义计算
 - 语言文化产业
- 国际上自然语言处理领域近年来有哪些最新的前沿进展?
 - 基础资源、语言学、大数据、机器学习和算法

- 中文信息处理的重要原始创新可能在哪里?
 - 中文语义理解与计算
- 中文信息处理相关产业发展的方向可能是什么?
 - 基于大规模语义计算的智能信息处理系统

- 对学会工作的希望和建议？
 - ACL进入CCF的一类会议
 - 更加重视国际顶级会议，而不仅仅是SCI论文
 - 学报进入EI

● CIP的发展战略

○ 基于多层次篇章语义的机器翻译

什么是多层次篇章语义？




- 词汇语义
- 句子语义
- 篇章和篇章语义

语义是怎么表示的？



- 词汇语义
- 浅层语义
 - 谓词论元
- 谓词逻辑
- 分布式表示

谓词演算: 实例



句法表示

语义表示

分布式表示



女人 = (100, 200, 0, 500, 50)

词汇表: {金钱, 化妆品, 胡须,

男人 = (150, 10, 200, 50, 150)

Why now: Semantics-based SMT



- 短语和句法模型愈来愈难以依靠增加数据和模型复杂度来提高性能
- 大规模语义资源（如WordNet/HowNet, Propbank, 知识图谱, 基于互联网数据挖掘的语义资源和本体资源等）不断建设和完善
- 自然语言分析技术的进展（词法、句法、语义和篇章）
- 统计机器学习技术（特别是深度学习）在语音识别和某些自然语言处理任务上的成功应用

- **Terminology:** 话语？篇章？语篇？文本？
- **Taxonomy:**
 - **From:** 词、形态、词性、短语、句法、语义
 - **To:** 篇章
- **Definition (from Wiki):**
 - **A unit of text used by linguists for the analysis of linguistic phenomena that range over more than one sentence (even within a single sentence).**

篇章的话题结构




图1. 微观话题结构实例[宋柔, 2012]

篇章的逻辑语义结构



(JS (XJ₁ 如果 你 不 出面 干预 ,) (RB (XJ₂ 他 即使 把 设备 卖 了 ,) (XJ₃ 也 没 人 阻止 得 了 他 。))) ←




图 2. 篇章的逻辑语义结构 (包括关系结构、关系类别、关联词和依存关系，JS:假设； RB:让步； XJ:小句) ←

What is Discourse: 核心问题



苏州大学
SOOCHOW UNIVERSITY

- 篇章研究核心问题的可计算性：结构和特征

- 篇章的基本结构分析：

篇章结构指的是篇章内部关系的不同结构化表达形式，主要包括逻辑语义结构(Discourse Relations)、指代结构(Co-reference)、话题结构(Topics)、功能结构(Functions)、事件结构(Eventualities)等范畴

- 篇章的基本特征的研究：

衔接性(cohesion)、连贯性(coherence)、意图性(intentionality)、可接受性(acceptability)、信息性(informativity)、情景性(situationality)和跨篇章性(intertextuality)等七个基本特征

Why Discourse-based SMT



- Leverage on Discourse-level Knowledge for SMT: 时态, 格, 词汇选择, 话题一致性, 连接词, 句子结构, 篇章结构, 指代, 评价...
- International research community?
- Now it is a good timing: an emerging, promising and important research ...

Why Discourse-based SMT




苏州大学
SOOCHOW UNIVERSITY

- 少年姓孙， // [并列] 属马， / [并列] 比小水小着一岁， /// [并列] 个头也没小水高， // [转折] 人却本分实诚。 (贾平凹《浮躁》)
- The boy, a member of the Sun family, // [并列] was born in the year of the horse. / [并列] Although he was a year younger /// [并列] and a head shorter than Water Girl, // [转折] he was honest and sincere .
(Goldblatt, 1991)

Why Discourse-based SMT



苏州大学
SOOCHOW UNIVERSITY





● CIP的发展战略

○ 基于多层次篇章语义的机器翻译

Semantics-based SMT: the state-of-the-art



- 基于词汇语义的机器翻译
- 基于谓词论元结构的机器翻译
- 基于谓词演算的机器翻译
- 基于分布式表示和深度学习的机器翻译

Discourse-based SMT: the state-of-the-art



蘇州大學
SOOCHOW UNIVERSITY

- Document level translation
- Topic-based translation
- RST structure-based translation
- Lexical cohesion-based translation
- Coherence-based translation
- Discourse connectives translation
- Discourse-aware decoding
- Discourse-based translation evaluation
-

Discourse-based SMT: Previous and the State-of-the-art Work



- Daniel Marcu, Lynn Carlson, and Maki Watanabe. *The automatic translation of discourse structures*. NAACL-2000
- Xiaodong Shi and Yidong Chen. *Previews of approach to discourse-based machine translation*. Proc. Frontiers of Chinese Information Processing, 2006
- Bonnie Webber's work: ...
- Mei Tu, Yu Zhou and Chengqing Zong. *A novel translation framework based on rhetorical structure theory*. ACL-2013
- Mei Tu, Yu Zhou and Chengqing Zong. *Enhancing grammatical cohesion: generating transitional expressions for SMT*. ACL-2014
-

Discourse-based SMT: Our Work



- Cache-based Document-level SMT
- Document-level Tense Models
 - N-gram-based
 - Classifier-based
- Zhengxian Gong, Min Zhang, Chew Lim Tan and Guodong Zhou.
Cache-based document-level SMT. EMNLP-2011
- Zhengxian Gong, Min Zhang, Chew Lim Tan and Guodong Zhou.
N-gram-based tense models for SMT. EMNLP-2012
- Zhengxian Gong, Min Zhang, Chew Lim Tan and Guodong Zhou.
Classifier-based tense models for SMT. COLING-2012

Discourse-based SMT: Our Work



- Document-level topic model for rule selection
 - Similarity model
 - Sensitivity model
- Xinyan Xiao, Deyi Xiong, Min Zhang, Qun Liu and Shouxun Lin. *A topic similarity model for hierarchical phrase-based translation.* ACL-2012
- Min Zhang, Xinyan Xiao, Deyi Xiong and Qun Liu. *Topic-based dissimilarity and sensitivity models for translation rule selection.* Journal of Artificial Intelligence Research, 2014

Discourse-based SMT: Our Work



- Discourse-based SMT: cohesion and coherence
 - Lexical cohesion: lexical device
 - Lexical chain cohesion: lexical chain
 - Topic coherence

- Deyi Xiong and Min Zhang. *A topic-based coherence model for SMT*. AAAI-2013
- Deyi Xiong, Guosheng Ben, Min Zhang, Yajuan Lü and Qun Liu. *Modeling lexical cohesion for document-level MT*. IJCAI-2013
- Deyi Xiong, Yang Ding, Min Zhang and Chew Lim Tan. *Lexical chain based cohesion models for document-level SMT*. EMNLP-2013

Semantic-based SMT: Our Work



- Lexical semantics for SMT
 - Word sense induction
- Predicate-argument for SMT
 - Predicate translation
 - Argument reordering
- Deyi Xiong and Min Zhang. *A Sense-based Translation Model for Statistical Machine Translation*. ACL-2014
- Deyi Xiong and Min Zhang. *Modeling the Translation of Predicate-Argument Structure for SMT*. ACL-2012

- 词汇和句子语义机器翻译：语义推导和语义合成性
- 双语篇章对齐语料的构建
 - 切分、层次结构、关系
 - 中心、角色分布
- 篇章结构的翻译
- 话题结构的翻译
- 衔接性和连贯性建模
- 篇章级机器翻译评测

感谢！

ありがとう！

감사합니다!

Thank you!

Terima kasih !

நன்றி!

ขอบคุณ!

Cảm On Bạn!

请帮忙注册： 谢谢！



1. COLING-2014 Tutorial (Aug 23)

**“Dependency Parsing: Past, Now
and Future”**

2. ACL-2014 Tutorial (June 22)

**“Semantics, Discourse and Machine
Translation”**