

# Learning Linear Ordering Problems for Better Translation

Roy Tromble, Google Pittsburgh

Jason Eisner, Johns Hopkins

August 7, 2009

# Overview

- Monotonic translation is easier
- Construct sentence-specific Linear Ordering Problems to put German sentences in English word order
- Use reordered sentences to train and decode with another MT system (makes its reordering job easier\*)
- Get better translations\*

\* Hopefully

Deshalb unterstützen und begrüßen **wir die vom Haushaltsausschuß** eingebrachten Vorschläge für eine Aufstockung des Haushalts für Prince.

Thus support and welcome **we the from the budget committee** tabled proposals for an increase of the budget for Prince.

Deshalb **wir** unterstützen und begrüßen die eingebrachten Vorschläge **vom Haushaltsausschuß** für eine Aufstockung des Haushalts für Prince.

---

Lassen Sie mich zu einem letzten Punkt **kommen**, der die verbesserte Koordinierung zwischen der Politik der Entwicklungszusammenarbeit und den externen Aspekten der gemeinsamen Fischereipolitik **betrifft**.

Let you me to a last point **come**, which the improved coordination between the policy of the development cooperation and the external aspects of the common fisheries policy **concerns**.

Lassen Sie mich **kommen** zu einem letzten Punkt, der die verbesserte Koordinierung zwischen der Politik **betrifft** der Entwicklungszusammenarbeit und den externen Aspekten der gemeinsamen Fischereipolitik.

# “Better Translation”

| System     | BLEU         | TER          |
|------------|--------------|--------------|
| Moses      | 25.55        | 59.76        |
| This paper | <b>26.40</b> | <b>58.63</b> |

- 2000 German-English Europarl sentences
- Significant according to a paired permutation test

# Translation is hard

- *Das muß ich erst einmal klären.*
- *That must I for starters resolve.*
- I will have to look into that.

# Monotonic translation is easier

- *Das muß ich erst einmal klären.*
- *ich muß erst einmal klären Das.*
  - I will have to look into that.
- Prior work: Collins, Koehn, Kučerová (2005)

# Reordering automatically

| <S> | PDS | VMFIN | PPER | ADV  | ADV    | VVINF  | </S> |
|-----|-----|-------|------|------|--------|--------|------|
|     | Das | muß   | ich  | erst | einmal | klären |      |

5

For every pair of words

$$\hat{\pi} = \arg \max_{\pi \in \Pi_n} \sum_{1 \leq i < j \leq n} \theta \cdot \phi(w, \pi_i, \pi_j)$$

# The Linear Ordering Problem

|        | Das | muß | ich  | erst | einmal | klären |
|--------|-----|-----|------|------|--------|--------|
| Das    |     | 0.8 | 0.1  | 2.0  | -0.6   | -1.7   |
| muß    |     |     | -5.4 | 8.7  | 8.1    | 14.8   |
| ich    |     |     |      | 3.0  | 3.7    | 16.0   |
| erst   |     |     |      |      | 7.7    | 1.9    |
| einmal |     |     |      |      |        | 2.0    |
| klären |     |     |      |      |        |        |



# Why this model?

- Looks only at the entire source sentence, and reorders for the target language
- Can assign a different score to every permutation
- Can incorporate linguistic information via features
- Can integrate with many translation models

# The First difficulty

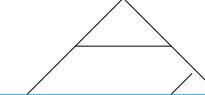
- The Linear Ordering Problem is NP-complete!
- Proposed solution:
  - Iterate greedy local search
  - with a very large neighborhood
  - using dynamic programming

# Local Search using Dynamic Programming

$$S \rightarrow S_{0,n}$$

$$S_{i,k} \rightarrow S_{i,j} S_{j,k}, \max(0, \Delta_{i,j,k})$$

$$S_{i-1,i} \rightarrow \pi_i$$



Iterate!

*Das muß ich erst einmal klären*

*ich muß erst einmal klären Das*

# Observations

- There are  $n!$  permutations to try
- Even the subset we search at each iteration is exponentially large
  - $O(\approx 5.83^n)$
- But search by dynamic programming is fast!
  - $O(n^3)$  with no grammar constant!
- What about the grammar weights?

$$\Delta_{i,j,k} = \sum_{\ell=i+1}^j \sum_{r=j+1}^k B[\pi_r, \pi_\ell] - B[\pi_\ell, \pi_r]$$

# Grammar Weights

- Dynamic programming to the rescue!

$$\Delta_{i,j,k} = \sum_{\ell=i+1}^j \sum_{r=j+1}^k B[\pi_r, \pi_\ell] - B[\pi_\ell, \pi_r]$$

|     | ich  | erst | einmal | klären |
|-----|------|------|--------|--------|
| Das | 0.1  | 2.0  | -0.6   | -1.7   |
| muß | -5.4 | 8.7  | 8.1    | 14.8   |

$$\begin{aligned}\Delta_{i,j,k} &= \Delta_{i,j,k-1} + \Delta_{i+1,j,k} - \Delta_{i+1,j,k-1} \\ &\quad + B[\pi_k, \pi_{i+1}] - B[\pi_{i+1}, \pi_k]\end{aligned}$$

# The Second difficulty

- Where do we get the feature weights?
- No previous learning algorithm for the LOP
  - Can't efficiently find the best permutation according to the current model
  - Can't efficiently compute the partition function
- Proposed solution:
  - Approximate perceptron

# Learning for the LOP

- Align training sentences
- Compute German' from alignments
- Initialize parameters using log-odds
- Iterative training using greedy local search as an approximation to the true model optimum for the perceptron
- Reordered word pairs:
  - 64% precision
  - 21% recall

# Integration with Translation

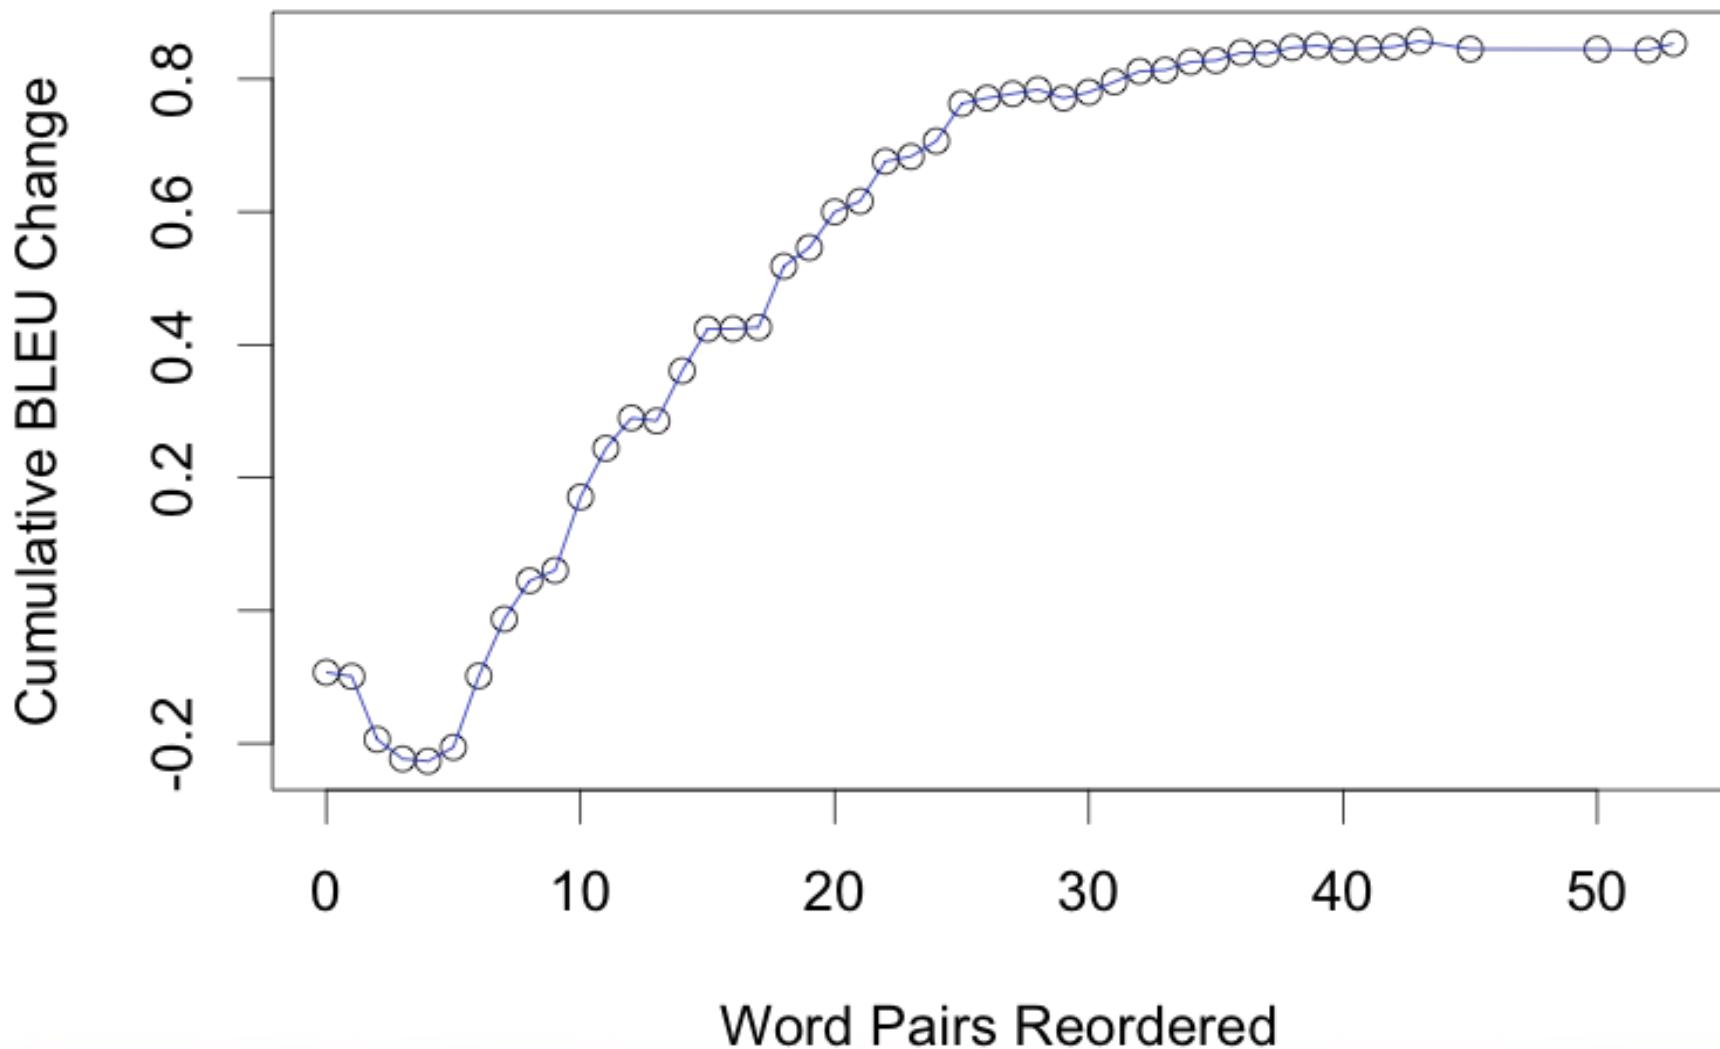
- Reorder the training, dev, and test sentences
- Standard Moses pipeline:
  - Align and learn phrase tables from reordered training sentences
  - Minimum error rate training over reordered dev sentences
  - Decode reordered test sentences

# Better Translation

| System                             | BLEU         | TER          |
|------------------------------------|--------------|--------------|
| Moses + MSD                        | 25.55        | 59.76        |
| LOP Preprocessing +<br>Moses       | <b>26.40</b> | <b>58.63</b> |
| LOP Preprocessing +<br>Moses + MSD | <b>26.44</b> | 59.23        |

- 2000 German-English Europarl sentences
- Significant according to a paired permutation test

# BLEU Improvement by Amount of Reordering



# Conclusion

- Proposed a novel model of reordering for machine translation
  - Novel search and learning algorithms for this model
- Even as preprocessing, outperforms Moses' integrated reordering model
  - Could be integrated into many decoders
  - Could reorder phrases instead of words

# Thanks!

- Much more in my dissertation:
  - More local search neighborhoods
  - Learning methods using likelihood/sampling
  - Methods for integrating LOP model into decoder
- <http://nlp.cs.jhu.edu/~royt/>