

4. 自動評価尺度 BLEU

内山将夫@NICT
mutiyama@nict.go.jp

自動評価尺度 BLEU

Kishore Papineni, Salim Roukos, Todd Ward and Wei-Jing Zhu. (2002) BLEU: a method for Automatic Evaluation of Machine Translation. ACL.

前提：

MT訳とプロの翻訳者による(複数の)翻訳が似ていれば似ているほど、そのMT訳は良いだろう。

自動評価に必要なもの

- (複数の) 良質の翻訳
あらかじめ用意しておく
- 似ている度合を測定する尺度 → BLEU

注：BLEUの妥当性の日本語についての現状

- これから紹介するBLEUについて，
- そのMTの評価尺度としての妥当性を検討したものは，
- 中国語-英語，アラビア語-英語が主であり，
- 中日や英日で，しっかりと検証した研究はないようである．
- これについて，我々は，
- NTCIR-7における日英特許翻訳タスクを通じて
- 調査する予定であるが，
- 今のところは，そのような調査結果はないようであるので，
- 英語を例文として利用する．

ngram の重なりによる類似度の例

1番目の良いMT訳の方が，参照訳と共通する ngram が多い．

MT 訳

1. 1It is a guide to action 2which 3ensures that the military
4always obeys the 5commands 6of the party.
2. It is to ensure the troops forever hearing the activity
guidebook that party direct

参照訳

1. 1It is a guide to action that 3ensures that the military
will forever heed Party 5commands.
2. It is the guiding principle 2which guarantees the military
forces 4always being under the command 6of the party.
3. It is the practical guide for the army 4always to heed the
directions 6of the party.

一般に

1. 多くの ngram を参照訳と共有する MT 訳の方が
2. そうでないものよりも良い訳と言えるのではないか

欠点

1. ngram の共有は字面しかみていないので，同義語でも異なるとみなされる．また，活用を考慮していない
2. 語順があまり評価に反映されない

ngramの重なり具合の測り方の悪い例

$$\text{ngram 精度} = \frac{\text{参照訳中にある ngram 数}}{\text{MT 訳中の ngram 数}}$$

不都合な例

MT: the the the the the the the

Ref1: The cat is on the mat.

Ref2: There is a cat on the mat.

MT訳は the のみからなり, the は Ref1 と Ref2 の双方に出現しているため, 上記定義だと

$$1\text{gram 精度} = \frac{7}{7}$$

となる. これはおかしい.

修正された ngram 精度

$$P_n = \frac{\Sigma_{\text{ngram}} \text{ある参照訳での ngram の共有数の最大値}}{\text{MT 訳中の ngram 数}}$$

MT: the the the the the the the

Ref1: The cat is on the mat.

Ref2: There is a cat on the mat.

$$P_1 = \frac{2}{7}$$

$$P_2 = 0$$

最初の例での計算

$$\text{MT1: } P_1 = \frac{17}{18} = 0.94, P_2 = \frac{10}{17} = 0.59$$

$$\text{MT2: } P_1 = \frac{8}{14} = 0.57, P_2 = \frac{1}{13} = 0.08$$

MT 訳

1. It is a guide to action which ensures that the military
always obeys the commands of the party.
2. It is to ensure the troops forever hearing the activity
guidebook that party direct

参照訳

1. It is a guide to action that ensures that the military
will forever heed Party commands.
2. It is the guiding principle which guarantees the military
forces always being under the command of the party.
3. It is the practical guide for the army always to heed the
directions of the party.

複数文を翻訳したときの ngram 精度

$$P_n = \frac{\sum_{\text{MT 訳}} \sum_{\text{MT 訳}} \text{ngram} \text{ 修正された共有 ngram 数}}{\sum_{\text{MT 訳}} \sum_{\text{MT 訳}} \text{ngram} \text{ ngram の数}}$$

- 分母としては，全ての MT 訳における全ての ngram の数
- 分子は，各 MT 訳について，修正した ngram の共有数を求めて，それを全 MT 訳について足したもの

修正 ngram 精度の統合

$$\sum_{n=1}^N \frac{1}{N} \log P_n$$

P_n = 修正 ngram 精度

N = ngram の最大長 (英語では4が多い)

いくつもの ngram 精度を組合せることにより，数値が安定することを意図している．

長さに関する修正 ngram 精度 P_n の性質

参照訳よりも長い MT 訳の場合

共有 ngram 数は，参照訳にある ngram 数を越えないので，参照訳よりも長い MT 訳は， P_n が小さくなる．

参照訳よりも短い MT 訳の場合

短い訳の ngram 精度は，高くなる．これは困った．

$$P_1 = 2/2, P_2 = 1/1$$

MT 訳: of the

参照訳 1: It is a guide to action that ensures that the military will forever heed Party commands.

参照訳 2: It is the guiding principle which guarantees the military forces always being under the command of the party.

参照訳 3: It is the practical guide for the army always to heed the directions of the party.

短かすぎる MT 訳へのペナルティ

MT 訳の長さとはコーパス中の文長 (単語数) の比較

$$c = \sum_{MT \text{ 訳}} MT \text{ 訳の長さ}$$

$$r = \sum_{\text{参照訳集合}} \text{参照訳中で, 対応する } MT \text{ 訳に最近の長さ}$$

コーパス全体で, 長さを計算することにより, 一文一文の長さの違いには, あまり影響されないようにする.

BP (brevity penalty)

$$BP = \begin{cases} 1 & \text{if } c \geq r \\ \exp(1 - r/c) & \text{if } c < r \end{cases}$$

- MT 訳 \geq 参照訳 のときには, BP = 1 (なにもしない)
- MT 訳 $<$ 参照訳 なら BP $<$ 1 としてペナルティとする

自動評価尺度 BLEU

$$\text{BLEU} = \text{BP} \times \exp\left(\sum_{n=1}^N \frac{1}{N} \log P_n\right)$$

- 短いMT訳へのペナルティ ×
- ngram 精度の幾何平均

BLEUにより始めて可能になること

- システムの安価で素早い比較

BLEUにより，開発 評価 開発 ... というサイクルが素早く回りはじめた．最近の統計的機械翻訳進展の原動力の一つである．

現状のMTの研究における，標準的な評価尺度である．

人手による評価とBLEUの比較

人手による評価

- 単言語グループ 10人 (英語を母語とするもの)
- 2言語グループ 10人 (中国語が母語)
- 各人は, 中英翻訳システムが翻訳した 500 文の英文のうちで 50 文を評価
- 各文は, 5つのシステム (S1,S2,S3,H1,H2) が英語に翻訳. ただし, H1 と H2 は人手による翻訳. H1 は日英ともに母語ではない. H2 は英語が母語.
- 評価の方法は, 1(非常に悪い) ~ 5(非常に良い) の点を付ける.
- 単言語グループは, 出力された英語の読み易さなどのみをチェック
- 2言語グループは, 入力中国語と出力英語とを比較してチェック
- 各人が, 各文毎に, 各システムの評価をするので, システムを比較するときには, 同一人の同一文におけるシステム間の評価値の差を求めて, その差が 0 かどうかにより, 検定をする.

評価値の差の検定 (paired t-test)

- ある人 u , ある文 i , あるシステム s について , 評価値 $r(u, i, s)$ がある .
- 同じ人と文について , 別のシステム s' について , 評価値 $r(u, i, s')$ がある .
- これより , s と s' の評価値の差は $d(u, i, s, s') = r(u, i, s) - r(u, i, s')$ である .
- これを全ての人と文について平均すると $m(s, s') = \Sigma_{u,i} d(u, i, s, s')$
- 分散は $v(s, s') = \frac{1}{n} \Sigma_{u,i} (d(u, i, s, s') - m(s, s'))^2$ である .
ただし , $n = \Sigma_{u,i} 1$.
- もし , s と s' で評価値に差がなければ , $m(s, s') = 0$ なので ,
- これが実際に 0 かどうかを調べるために ,

$$t = \frac{m(s, s')}{\sqrt{\frac{v(s, s')}{n-1}}}$$

を計算する .


- t がある値よりも大きければ , 統計的に有意差がある .

BLEUおよび人手による評価値

システム	BLEU	単言語	2言語
S1	0.0527	0	0
S2	0.0829	0.326	0.551
S3	0.0930	0.44	0.691
H1	0.1934	2.265	2.574
H2	0.2571	2.8	2.612


単言語グループと2言語グループにおける数値は、S1の数値を0とし、S2は、 $m(S1, S2)$ を評価値とし、 $S3 = S2 + m(S3, S2)$ というように、評価値の差に基づいて点数を付けた。

BLEUおよび人手による評価値




- 縦軸が評価値で，横軸がシステムである
- 0-1 に正規化したスコアを利用している
- BLEU と単言語および2言語の評価は似ている
- BLEU は単言語グループの評価に似ている
- S3 と H1 のような大きな差だけでなく，
- H1 と H2，S2 と S3 のような小さい差も検出可能である

BLEU と単言語グループのスコアの比較



BLEU は , 単言語グループのスコアと相関が高い

BLEU と単言語グループのスコアの比較



BLEU は , 2 言語グループのスコアとも相関が高い .

まとめ

- BLEU は MT 訳と参照訳との類似性を表す尺度である
- BLEU と人手評価との相関は高い

BLEU の欠点

- 意味は同じでも字面が違う ngram とマッチしない
- コーパス全体での値は求められるが文毎の値は求められない
→ どの文が上手く翻訳でき，どの文が翻訳できなかったかがわからない

しかし，現在では，ほぼ全ての研究で利用されている．