

# 15. フレーズテーブルの作り方

内山将夫@NICT  
mutiyama@nict.go.jp

# フレーズテーブルの作成手順

1. 初期単語アラインメント
2. 単語アラインメントの修正
3. 単語単位の翻訳確率の推定
4. フレーズ対応の抽出
5. フレーズへのスコアの付与

## 結果

英語句 ||| 日本語句 ||| スコア1 スコア2 ...

これらの句のスコアを上手く組み合わせて文全体のスコアを得る .

## 初期単語アラインメント

GIZA++ というフリーソフトウェアを利用することが多い。これを、たとえば、日英の方向に、

- IBM Model-1 (紹介済)
- HMM Model
- IBM Model-3
- IBM Model-4

を順番に適用していくことにより、日英の各文対応について、1対<sub>n</sub>の単語対応を得ることができる。  
英日にもすることにより、両方向に、1対<sub>n</sub>の単語対応を得る。

---

=====

単語アラインメントは未解決の問題だが、ある程度まではできるので、とりあえず、そこまでを前提にして、次に進んでいる。

# 日英単語アラインメントの例

	when	the	fluid	pressure	cylinder	31	is	used	,	fluid	is	gradually	applied	.
流体			*											
圧				*										
シリンダ					*									
3 1						*								
の														
場合	*													
は							*							
流体									*					
が										*				
徐々に											*			
排出											*			
さ												*		
れる												*		
こと												*		
と								*						
なる														
。													*	

# 日英単語アラインメントの例

	this	relation	must	be	maintained	even	after	passing	at	least	100,000	sheets	.
そして							*						
、				*									
上記	*												
関係		*											
を								*					
少なくとも									*				
10万											*		
枚											*		
通											*		
紙												*	
し									*				
て							*						
も							*						
維持					*								
し									*				
なけれ			*										
ば			*										
なら			*										
ない			*										
。													*

## 日英単語アライメントの例

	first	,	a	description	will	be	given	of	the	structure	of	the	wheels	2	.
まず	*														
、		*													
車輪													*		
2														*	
の												*			
構造											*				
について					*										
説明					*										
する					*										
。															*

## 英日単語アライメントの例

	流体	圧	シリンド	3 1	の	場合	は	流体	が	徐々に	排出	さ	れる	こと	と	なる
when						*										
the							*									
fluid	*															
pressure		*														
cylinder			*													
31				*												
is														*		
used															*	
,																
fluid							*									
is								*								
gradually									*							
applied										*						
.																

## 英日単語アライメントの例

	まず	、	車輪	2	の	構造	について	説明	する	。
first	*									
,		*								
a										
description							*			
will							*			
be							*			
given							*			
of				*						
the				*						
structure					*					
of						*				
the								*		
wheels		*								
2			*							
.										*

## 日英英日アラインメントの合成

- アラインメントの積集合 =  $I$

→ 精度の高い単語対応

- アラインメントの積集合 =  $U$

→ カバー率の高い単語対応

$I$  を出発点として  $U$  中のアラインメントを加えていく .

# 日英と英日の合成の例

	when	the	fluid	pressure	cylinder	31	is	used	,	fluid	is	gradually	applied	.
流体			I											
圧				I										
シリンダ						I								
31							I							
の														
場合	I													
は		U					U							
流体									I					
が										I				
徐々に											I			
排出												U	U	
さ													U	
れる							U						U	
こと													U	
と								U	U					
なる														
。														I

## 日英と英日の合成の例

	this	relation	must	be	maintained	even	after	passing	at	least	100,000	sheets	.
そして								U					
、					U								
上記	I												
関係		I											
を									U				
少なくとも										U	I		
10万												I	
枚											U	U	
通								U			U		
紙												U	
し							U	U					
て						U							
も							I						
維持					I								
し								U					
なけれ			U										
ば			U										
なら			I	U									
ない			U										
。													I

## 日英と英日の合成の例

	first	,	a	description	will	be	given	of	the	structure	of	the	wheels	2	.
まず	I														
、		I													
車輪													I		
2														I	
の								U	U			U			
構造											I				
について					U							U			
説明				U		I	U	U							
する					U							U			
。														I	

# 合成手順

```
#  
# アライメント候補 = {(e_i, f_j)} は e_i + f_j が小さいものから並  
# んでいる。そうすることにより、文頭のものから優先して対応付けてい  
# くことができる。  
  
#  
  
日英英日アライメントの合成()  
隣接点集合 = ((-1,0),(0,-1),(1,0),(0,1),(-1,-1),(-1,1),(1,-1),(1,1))  
アライメント候補 = 積集合 I(日英アライメント, 英日アライメント)  
隣接する 1 対 1 の点を追加する()  
その他の点を加える()  
アライメント候補を返す  
end  
  
隣接する 1 対 1 の点 N を追加する()  
while true  
  for (j, e) アライメント候補  
    for (j0, e0) 隣接点 (j,e) 和集合 (日英, 英日)  
      if(j0 も e0 もアライメント候補で使われていない)  
        (j0, e0) をアライメント候補に追加する (それでも 1 対 1 が壊れない)  
      end  
    end  
  end  
  アライメント候補に追加がなければ終了する  
end  
end  
  
#  
# なるべく多くの点を加えたいが、日英共に使われているのは加えない  
#  
その他の点 0 を加える()  
for (j,e) 和集合 (日英, 英日)  
  if (j か e のどちらかがアライメント候補で使われていない)  
    (j,e) をアライメント候補に含める  
  end  
end  
end
```

## 合成の例

(I=積集合 , N=隣接点 , O=その他の追加, U=削除された点)

	when	the	fluid	pressure	cylinder	31	is	used	,	fluid	is	gradually	applied	.
流体			I											
圧				I										
シリンダ					I									
31						I								
の														
場合	I													
は		N					O							
流体									I					
が									I					
徐々に										I				
排出										U	N			
さ											O			
れる						U					O			
こと											O			
と							O	O						
なる														
。														I

# 合成の例

	this	relation	must	be	maintained	even	after	passing	at	least	100,000	sheets	.
そして							O						
、					O								
上記	I												
関係		I											
を							O						
少なくとも								O	I				
10万											I		
枚											U	N	
通								U			O		
紙												O	
し							U	O					
て							O						
も							I						
維持					I								
し								O					
なけれ			O										
ば			O										
なら			I	U									
ない			O										
。													I

# 合成の例

	first	,	a	description	will	be	given	of	the	structure	of	the	wheels	2	.
まず	I														
、		I													
車輪													I		
2														I	
の								O	N			U			
構造										I					
について					U							N			
説明				O	I	O	O								
する				O								O			
。														I	

## 単語単位の翻訳確率

- これまでに，日英，英日の1対nおよびm対1の単語対応を組み合わせてm対nの単語対応を得る方法を示した。
- これから，それを利用して，フレーズを抽出する方法を示す。
- その前に，ここで得たm対nの対応から単語単位の辞書を作る方法を示す。

## 単語単位の辞書

### アライメント

	e1	e2	e3	e4
j1	*		*	
j2				
j3		*		
j4				*

から， $(j1, e1)$ ,  $(j1, e3)$ ,  $(j3, e2)$ ,  $(j4, e4)$  の単語対応がとれるので，これから， $j \rightarrow e$  と  $e \rightarrow j$  方向の辞書がつくれる．更に，

$$P(j|e) = \frac{\#(j, e)}{\sum_{j'} \#(j', e)}$$

$$P(e|j) = \frac{\#(j, e)}{\sum_{e'} \#(j, e')}$$

により，単語単位の翻訳確率が求まる．(スムージングをしても良い)

# 単語単位の辞書：頻度 日本語単語 英語単語

2230457 、 the		
1811473 、 ,	146977 さ to	87623 する a
1804260 。 .	146509 2 2	87410 において in
1802874 の of	143482 を for	85936 1 first
1767572 の the	142192 し to	85471 その the
704450 に to	140494 出力 output	84919 として as
668066 は the	139684 制御 control	84888 第 first
584253 が is	135600 が are	84615 に with
543500 は is	130609 は are	84356 メモリ memory
527825 に in	128437 この this	82459 6 6
480009 する the	126068 実施 embodiment	82098 値 value
448118 を is	124007 3 3	81423 に ,
376711 と and	117825 する to	79752 情
376195 、 a	112598 よう as	報 information
365107 図 fig.	111611 た a	79287 1 2 12
345039 を of	110575 ステップ step	79126 1 1 11
287703 ) )	109286 4 4	79048 の for
285186 ( (	106286 および and	78406 例 embodiment
281659 信号 signal	105113 を are	78238 に at
272811 を to	101722 で by	78233 こと can
245721 データ data	101291 及び and	77678 接続 connected
230038 回路 circuit	100440 示す shown	77671 、 an
224630 で in	98899 が of	77513 部 portion
209459 で ,	98684 が can	75575 画像 image
202160 に on	97290 示す in	75000 / /
198721 1 1	96570 5 5	73687 に into
196317 から from	95364 1 0 10	72920 上記 the
193708 この the	95330 電圧 voltage	72590 層 layer
177043 に shown	93903 する be	72466 第 second
175086 し the	93619 入力 input	72399 7 7
166888 、 and	92337 さ in	72231 膜 film
164284 た the	89141 形成 formed	
154881 は a		

# 単語単位の辞書 : $P(\text{日}|\text{英})$ でソート

e m u	emu	カテプシン	cathepsin	C d x	cd.sub.x
S C L K	sclk1	W C B R B	wcbrb		
+ .sub.+		V p k	vpk	x	.times..sigma..sub.i3
ウェル	-well	V f v	vfv	i n o d e	inode
L R D	1rd	T R B L	trbl	S E N P n	senpn
L A T	lat.sub.	P D R H I T	pdrhit	S D B n	sdbn
M R S O U T	mrsout	C t s	c.sub.ts	P F A i	pfai
0 0 0 0 0 0 0		4 0 8 0	4080	M O P L S	mopl
0 00000000		試験	under-test	K F L E A K M	
W D R	wdr	r o m a r e a	romarea	X k	fleakmx
C B S	cbs.sub.	R M I S	rmis	C A D	cad7
P x R	pxr	P G	pg.sub.	9 8 0	980.degree.
M B T	mbt	C T R L R	ctrlr	8 5 1 0	8510
M B Q	mbq	3 1 1	3.sub.11	8 3 1	83.sub.1
B R E	bre	3 0 9 0	3090	1 0	ta.sub.10
6 8 5	685	2 0 4 1	204.sub.1	偏り	one-sidedness
. 38q		1 0 0 7 0	10070	微動	micromotion
r a m a r e a	ramarea	セルフプリチャ-		q	se.sub.1-q
k D a	kda	ジ	self-precharge	ment	ment
S d w	s.sub.dw	w a i t i d	waitid	e E C O N O M	
R H I T	rhit	Z M R	zmr	Y	eeconomy
C S	cs.sub.	V p a s s	vpass	T R R Q	trrq
d s p l s	dspls	O P R H	oprh	R S D F	rsdf
Z O D L	zodl	L I O i	lio	R P R G	rprg
G C F	gcf	1 9 1 6	1916	Q H N	qhn
7 0 3 0	7030	日	date-indicating	I R Q	irq9
p r e t r n	pretrn	r b l j	rblj	H N M O S	hnmos
d q m x	dqmx	Z C O	zco	G L j	glj
2 2.sup.		W S E L	wsel.sub.	E A V	eav
w r e q	wreq	V T T A O	vttao	D W D E	dwde
R W C	rwc	R S R a v	rsr.sub.av	B j b	bjb
S G P	sgp	P D R T P i	pdrtpi	B R I a	bria
3 0 8 0	3080	N s a	nsa.sub.	5 0 2 2	5022
排気	exhaling	I a b	i.sub.ab	3 1 2 2	3122

# 単語単位の辞書： $P(\text{英}|\text{日})$ でソート

オーディオ audio	d i g e s t digest	B G M M bgmm
p c h M O S F E	R X T p u l s	8 2 , 8 2 82
T pch-mosfet	e rxtpulse	スレッシュ threshold
I I D R iidr	D R a dra	q c qc
© ©	W B L n wbln	o a m oam
c o a r s e coarse	S P X spx	m e t a p h o
i r o m irom	S E L F O S C selfosc	r metaphor
V c c p vccp	F M T fmt	T H i d l th.sub.idl
G D I gdi	C A S I casi	S P K U spku
M S K i mski	P R E D pred	R M B rmb
C K M ckm	D T G dtg	R F I C rfic
N P R npr	C o p y copy	E X T C L K extclk
S P L spl	C A a caa	B L h blh
R H I T rhit	t P G R tpgr	4 0 9 0 4090
N O X .sigma.nox	d q m x dqmx	n M I S nmis
Z M C H G zmchg	X S U xsu	l u n c h e r luncher
S T X stx	V r c vrc	a u t o m a t o
R I T rit	V c o m H vcomh	n automaton
G B U F R gbufr	S l u slu	V h i g h vhigh
e x t Z R A S extzras	D B B a dbba	S L I F slif
M N P mnp	m p g m mpgm	G W D gwd
コースター coaster	f A fa	G F M gfm
S u p s.sub.up	X B L A xbla	E A D ead
9 1 0 0 9100	R E M E reme	D i n L B n dinlbn
e x t Z C A S extzcas	M B W mbw	C W L cwl
S H L shl	C l t clt	C T R L R ctrlr
I n z in.sub.z	C O C coc	B S B bsb
I m s i.sub.ms	C L E cle	1 , 5 5 5 1,555
B L r blr	R W L E rwle	w a i t i d waitid
フォーマツタ formater	R B L n rbln	v b a t vbat
	N B C nbc	f u p f.sub.up
	B T G btg	X S D xsd
		V Z vz
		S A N G sang
		M I S F E T Q h q.sub.h

# 単語単位の辞書：対数尤度比でソート

。	·		
の of			
、 ,	1 1 11	第 first	
、 the	値 value	よう as	
の the	この this	電流 current	
図 fig.	は the	電極 electrode	
信号 signal	層 layer	2 1 21	
) )	発明 invention	1 5 15	
( (	7 7	本 present	
データ data	/ /	動作 operation	
に to	画像 image	2 2 22	
が is	膜 film	部 portion	
回路 circuit	8 8	基板 substrate	
と and	方向 direction	半導体 semiconductor	
は is	2 0 20	として as	
1 1	1 4 14	図 figs.	
から from	に on	3 0 30	
に in	および and	示す shown	
出力 output	する the	トランジスタ transistor	
制御 control	1 3 13	例 embodiment	
2 2	処理 processing	に shown	
3 3	アドレス address	第 second	
を is	位置 position	レベル level	
4 4	、 a	端子 terminal	
電圧 voltage	形成 formed	装置 apparatus	
実施 embodiment	及び and	装置 device	
1 0 10	で in	を of	
ステップ step	ゲート gate	状態 state	
5 5	9 9	記録 recording	
入力 input	1 6 16	1 first	
メモリ memory	接続 connected	ない not	
情報 information			
1 2 12			
6 6			

## $P(*)|\text{流体})$ と $P(*)|\text{fluid})$

```
# P(*)|流体)
流体 fluid 0.84868421
流体 hydraulic 0.01946272
流体 gas 0.01151316
流体 fluids 0.01096491
流体 flow 0.01041667
流体 liquid 0.00849781
流体 liquid-pressure 0.00603070
流体 hydrodynamic 0.00575658
流体 working 0.00301535
流体 piston 0.00274123
```

```
# P(*)|fluid)
fluid 流体 0.45072063
fluid 液 0.23875382
fluid 油 0.10642015
fluid 液体 0.02576794
fluid ブレーキフルード 0.01892561
fluid 流動 0.01368467
fluid 油圧 0.00873490
fluid 流 0.00844373
fluid 作動 0.00698792
fluid 連 0.00684234
```

## フレーズ対応の抽出

これまでに

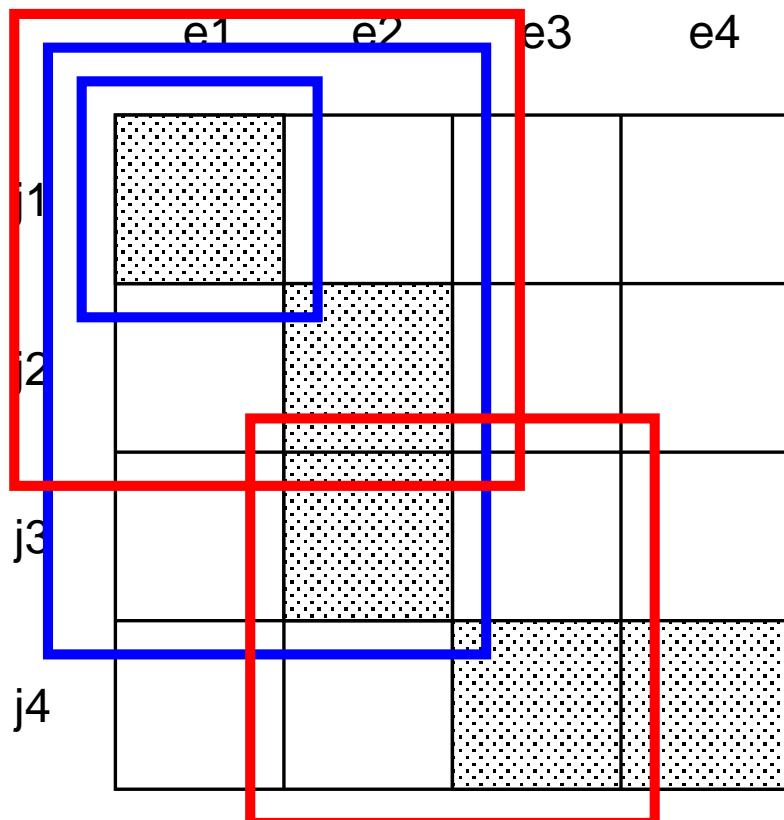
	e1	e2	e3	e4
j1	*			
j2		*		
j3		*		
j4			*	*

のような単語対応を得る方法を述べた。次は、ここから句対応を得る方法を述べる。

基本方針

単語対応に整合するような、なるべく多くの句対応を得る。

## 整合的な句の例



青はOK. 赤はダメ.

日本語の句  $J$  と英語の句  $E$  について,  $j \in J$  の対応先を  $e(j)$  とすると,  $e(j) \in E$  でないといけない.

同様に  $e \in E$  の対応先を  $j(e)$  とすると,  $j(e) \in J$  である. つまり, 対応の相手は, 日本語句  $J$  内の単語と英語句  $E$  内の単語に限られる.

# 句対応の例：fluid を含む句の例

( 流体 ) ||| ( fluid ) ||| 0.166667 0.0307503 1 0.623726 2.718  
( 流体 壓 ) ||| ( fluid pressure ) ||| 0.5 0.000742744 1 0.200361 2.718  
( 流体 壓 ) ||| ( fluid pressure ) ||| 0.5 0.010301 1 0.266855 2.718  
( 流体 壓 源 ) ||| ( fluid pressure source ) ||| 1 0.000104349 1 0.159524 2.718  
( 流体 壓 源 ) 17 ||| ( fluid pressure source ) 17 ||| 1 9.465e-05 1 0.132599 2.718  
( 流体 壓 源 ) ||| ( fluid pressure source ) ||| 1 0.00144721 1 0.212466 2.718  
) の 送 液 ||| ) of fluid ||| 1 2.88816e-05 1 0.0150938 2.718  
) の 送 液 が ||| ) of fluid has ||| 1 6.6955e-06 1 0.000451654 2.718  
) の 送 液 が あつた ||| ) of fluid has taken ||| 1 2.55555e-09 1 7.43761e-07 2.718  
、 3 は 液 壓 制 御 装置 ||| , a fluid pressure control apparatus 3 ||| 1 2.28706e-07 1 0.000292281 2.718  
、 3 は 加工 液 ||| , 3 a dielectric fluid ||| 1 3.63074e-05 1 3.96712e-06 2.718  
、 3 は 加工 液 、 ||| , 3 a dielectric fluid , and ||| 1 1.47644e-05 1 5.67333e-08 2.718  
、 38 は 加工 液 ||| , 38 is working fluid ||| 1 0.0088037 1 0.000662696 2.718  
、 38 は 加工 液 供給 ||| , 38 is working fluid supplying ||| 1 0.0062226 1 4.34916e-05 2.718  
、 38 は 加工 液 供給 手段 ||| , 38 is working fluid supplying means ||| 1 0.00427184 1 3.16053e-05 2.718  
、 41 d 、 流体 ||| , 41d , fluid ||| 1 0.0345864 1 0.000467132 2.718  
、 41 d 、 流体 貯留 ||| , 41d , fluid storing ||| 1 0.00048108 1 8.14764e-05 2.718  
、 41 d 、 流体 貯留 タンク ||| , 41d , fluid storing tank ||| 1 0.000284362 1 7.14906e-05 2.718  
、 6 および 流体 ||| and 6 and a fluid ||| 1 0.00410477 1 0.00964129 2.718  
、 6 および 流体 測 温 ||| and 6 and a fluid temperature measuring ||| 1 7.86306e-06 1 0.000721089 2.718  
、 61 ' は 伝 熱 流体 ||| , 61 ' a heat-transfer fluid ||| 1 0.00216443 1 0.000518098 2.718  
、 61 は 伝 熱 流体 ||| , 61 is a heat-transfer fluid ||| 1 0.0185343 1 0.00119982 2.718  
、 77 は 加工 液 ||| , 77 is a working fluid ||| 1 0.00864883 1 0.00028376 2.718  
、 77 は 加工 液 ノズル ||| , 77 is a working fluid nozzle ||| 1 0.00764329 1 0.000210182 2.718  
、 78 は 加工 液 ||| , and 78 is a working fluid ||| 1 0.00521192 1 1.09199e-05 2.718  
、 P は 流体 ||| , p denotes fluid ||| 1 0.122825 1 0.000660778 2.718  
、 Q は 流体 の 流量 ||| , q denotes flow rate of fluid ||| 1 0.0145985 1 2.77106e-05 2.718  
、 および 、 第 2 液 ||| and a second fluid ||| 0.333333 9.53798e-05 1 0.00106579 2.718  
、 および 、 第 2 液 壓 ||| and a second fluid pressure ||| 0.5 3.19513e-05 1 0.00045599 2.718  
、 この 液 ||| , and this fluid ||| 1 0.0557024 0.166667 0.000360561 2.718  
、 この 液 ||| , the fluid ||| 0.0285714 0.0047175 0.166667 0.014136 2.718  
、 この 液 ||| , this fluid ||| 1 0.0934985 0.333333 0.00959799 2.718  
、 この 液 ||| 8 , and this fluid ||| 1 0.0557024 0.166667 8.11983e-08 2.718  
、 この 液 壓 ||| , and this fluid pressure ||| 1 0.0186597 0.2 0.000154263 2.718  
、 この 液 壓 ||| , the fluid pressure ||| 0.25 0.00158031 0.2 0.00604794 2.718  
、 この 液 壓 ||| , this fluid pressure ||| 1 0.031321 0.4 0.00410641 2.718  
、 この 液 壓 ||| 8 , and this fluid pressure ||| 1 0.0186597 0.2 3.47399e-08 2.718  
、 この 液 壓 は ||| , and this fluid pressure is ||| 1 0.00536829 0.333333 4.16064e-05 2.718  
、 この 液 壓 は ||| , the fluid pressure is ||| 0.5 0.000454647 0.333333 0.0016312 2.718  
、 この 液 壓 は ||| 8 , and this fluid pressure is ||| 1 0.00536829 0.333333 9.36976e-09 2.718  
、 この 液 壓 を ||| , this fluid pressure is ||| 1 0.00774038 1 0.000828222 2.718  
、 この 作動 液 ||| , the hydraulic fluid ||| 0.125 0.000293068 1 0.000462624 2.718  
、 この 磁性 流体 ||| , the magnetic fluid ||| 0.333333 0.00118769 0.5 0.0798598 2.718  
、 この 磁性 流体 ||| the magnetic fluid ||| 0.0769231 0.000586521 0.5 0.239424 2.718  
、 この 磁性 流体 73 ||| , the magnetic fluid 73 ||| 1 0.00108018 1 0.0687977 2.718  
、 この 流体 ||| , each fluid ||| 1 0.00229816 1 0.000525922 2.718

# 句対応の例：自動車 を含む句の例

- 「自動車」|||, “automobile”||| 1 0.142122 1 0.0659882 2.718
- 「自動車 電話」|||, “automobile telephone”||| 1 0.0746708 1 0.0524542 2.718
- 「自動車 電話」|||, “automobile telephone”||| 1 0.0258531 1 0.0386858 2.718
- 「102 は 自動車 用」|||, 102 is a vehicle||| 1 0.000161113 1 0.00350135 2.718
- 「102 は 自動車 用 エンジン」|||, 102 is a vehicle engine||| 1 9.82163e-05 1 0.0031887 2.718
- 「3 は 自動車」|||, 3 a mobile||| 1 0.000371807 1 0.000168593 2.718
- 「3 は 自動車 電話」|||, 3 a mobile telephone||| 1 0.000195348 1 0.000134015 2.718
- 「3 は 自動車 電話 局」|||, 3 a mobile telephone office||| 1 7.2785e-05 1 3.45847e-06 2.718
- 「3 は 自動車 電話 局」|||, 3 a mobile telephone office||| 1 4.96815e-05 1 1.31658e-06 2.718
- 「7 は 自動車」|||, 7 a mobile||| 1 0.000370597 1 0.000217899 2.718
- 「7 は 自動車 電話機」|||, 7 a mobile telephone equipment||| 1 5.71506e-05 1 4.29458e-07 2.718
- 「7 は 自動車 電話機」|||, 7 a mobile telephone equipment||| 1 3.90098e-05 1 1.63488e-07 2.718
- 「EC セル 6 を通じて 自動車」||| vehicle through the ec cell 6||| 1 0.00011244 1 0.0167565 2.718
- 「OA 機器、自動車」|||, business machines, automobiles||| 1 3.50735e-05 1 2.53658e-07 2.718
- 「OA 機器、自動車」|||, business machines, automobiles and||| 1 4.58492e-06 1 9.529e-09 2.718
- 「OA 機器、自動車、精密」|||, business machines, automobiles and precision||| 1 3.50085e-07 1 2.718
- 「この よう な 電気 自動車」|||, such an electric vehicle||| 0.5 1.71207e-05 1 3.34838e-05 2.718
- 「この よう な 電気 自動車 の」|||, such an electric vehicle||| 0.5 4.51596e-06 1 3.34838e-05 2.718
- 「この ハイブリッド 自動車」|||, in the hybrid vehicle||| 1 0.000761246 0.5 0.00269411 2.718
- 「この ハイブリッド 自動車」|||, in this hybrid vehicle||| 1 0.0064154 0.5 0.00182924 2.718
- 「この ハイブリッド 自動車 500」|||, in the hybrid vehicle 500||| 1 0.00071914 1 0.0022104 2.718
- 「この ハイブリッド 自動車 500 において」|||, in the hybrid vehicle 500,||| 1 2.0926e-05 1 0.000841
- 「この ハイブリッド 自動車 600」|||, in this hybrid vehicle 600||| 1 0.00591218 1 0.00136645 2.718
- 「この ハイブリッド 自動車 600 において」|||, in this hybrid vehicle 600,||| 1 0.000172036 1 0.0005
- 「しかも 自動車」||| the automotive||| 0.1 0.000244648 1 0.0106571 2.718
- 「たとえば 自動車 用」|||, for example, an automobile||| 0.4 0.000664619 1 0.000540882 2.718
- 「たとえば 自動車 用 エンジン」|||, for example, an automobile engine||| 1 0.000405159 1 0.000492584
- 「コードレス 電話、自動車」|||, cordless telephones, car||| 1 0.0338496 1 0.000443696 2.718
- 「コードレス 電話、自動車 電話」|||, cordless telephones, car telephones||| 1 0.0157655 1 1.50196e-05
- 「ディーゼルエンジン 自動車 等」||| diesel engine automobiles and the like||| 1 0.0151152 1 3.01743e-05
- 「ディーゼルエンジン 自動車 等 に」||| on diesel engine automobiles and the like||| 1 0.00642812 1 2.24
- 「デジタル 自動車 電話」||| a digital cellular||| 0.2 2.39509e-05 1 0.000163602 2.718
- 「デジタル 自動車 電話 システム」||| a digital cellular system||| 1 9.71561e-06 1 0.000148973 2.718
- 「デジタル 自動車」||| the digital cellular||| 1 5.80871e-05 1 0.00122759 2.718
- 「デジタル 自動車 電話」||| the digital cellular telephone||| 1 3.05191e-05 1 0.000975814 2.718
- 「デジタル 自動車 電話 50」||| the digital cellular telephone 50||| 1 2.83228e-05 1 0.000844553 2.718
- 「デジタル 自動車 電話 50 において」||| the digital cellular telephone 50,||| 1 8.24154e-07 1 0.000844553
- 「ハイブリッド 自動車」||| a hybrid powered automobile||| 0.5 0.0354085 0.333333 8.32655e-05 2.718
- 「ハイブリッド 自動車」||| the hybrid car||| 0.166667 0.0441317 0.333333 0.0427639 2.718
- 「ハイブリッド 自動車」||| the hybrid vehicle||| 0.0263158 0.0102417 0.333333 0.0694053 2.718
- 「ハイブリッド 自動車 500」||| the hybrid vehicle 500||| 1 0.00967523 1 0.056944 2.718
- 「ハイブリッド 自動車 500 の」||| of the hybrid vehicle 500||| 1 0.00706622 1 0.0220125 2.718
- 「ハイブリッド 自動車 500 の ヨー 方向」||| yawing directions of the hybrid vehicle 500||| 1 0.001016
- 「ハイブリッド 自動車 の」||| the hybrid car||| 0.166667 0.0116407 1 0.0427639 2.718
- 「ファクシミリ、自動車」||| facsimiles, automotive vehicles||| 1 0.0560437 1 1.15431e-06 2.718
- 「プラスチック 廃棄 物、自動車」||| plastic wastes, and automobile||| 1 0.00690582 1 1.86092e-05 2.718

## 現行の句対応抽出の問題点

- 発見的な方法に基づいているため，改良がむずかしい

発見的な意味：抜き出された句対応が良い句対応かどうかの評価が，機械翻訳実験による性能の変化でしか測定できない．確率的なモデルがない．確率的なモデルがあれば，最尤となる句対応を選べば，そのモデルの観点からは最良の句対応が得られる．

- しかし「こういう句対応が良いのでは」といういくつかのモデルは，この発見的な方法と同等か少し性能が落ちる．

## 句の良さの評価

句単位に翻訳していく方法では，なるべく良い句対応を使った翻訳文を得たいので，そのためのスコアを定義する．一つの句対応について次の5つのスコアが良く使われる．

- 句翻訳確率  $\phi(\bar{f}|\bar{e})$
- 句翻訳確率  $\phi(\bar{e}|\bar{f})$
- 単語確率より  $\text{lex}(\bar{f}|\bar{e})$
- 単語確率より  $\text{lex}(\bar{e}|\bar{f})$
- 句ペナルティ  $\exp(1)$  (固定値)

句翻訳確率  $\phi(\bar{f}|\bar{e})$

$$\phi(\bar{f}|\bar{e}) = \frac{\text{count}(\bar{f}, \bar{e})}{\sum_{\bar{f}'} \text{count}(\bar{f}', \bar{e})}$$

$\text{count}(\bar{f}, \bar{e})$  = 句  $\bar{f}$  と  $\bar{e}$  が対応した回数

$\sum_{\bar{f}'} \text{count}(\bar{f}', \bar{e})$  = 句  $\bar{e}$  が出現した回数

$\phi(\bar{f}|\bar{e})$  は , 句  $\bar{e}$  が出現したとき , それが  $\bar{f}$  に翻訳される確率と考えられる .  $\phi(\bar{e}|\bar{f})$  も同様である .

単語確率より  $\text{lex}(\bar{f}|\bar{e})$

$$\text{lex}(\bar{f}|\bar{e}) = \max_{\mathbf{a}} P_w(\bar{f}|\bar{e}, \mathbf{a})$$

$$P_w(\bar{f}|\bar{e}, \mathbf{a}) = \prod_{i=1}^n E_w(f_i|\bar{e}, \mathbf{a})$$

$$E_w(f_i|\bar{e}, \mathbf{a}) = \frac{1}{\sum_{\{j|(i,j) \in \mathbf{a}\}} w(f_i|e_j)}$$

$$w(f_i|e_j) = \text{単語対応の確率} = \frac{\text{count}(f_i, e_j)}{\sum_{f'} \text{count}(f', e_j)}$$

$E_w(f_i|\bar{e}, \mathbf{a}) = w(f_i|e_j)$  の  $e_j$  に関する平均値

$P_w(\bar{f}|\bar{e}, \mathbf{a}) = E_w(f_i|\bar{e}, \mathbf{a})$  の積  $f_i$  の条件付き独立を仮定

$\text{lex}(\bar{f}|\bar{e}) = P_w(\bar{f}|\bar{e}, \mathbf{a})$  が最大の  $\mathbf{a}$  に関する確率を採用

## 句ペナルティ

$\exp(1)$ に固定 . スコアとしては , 対数を利用するので ,  
 $\log(\exp(1)) = 1$  となる .

翻訳に使われた句の  $\log(\text{句ペナルティ})$  の和は , 翻訳に使われた句の数である .

実際の翻訳のスコアには , この句ペナルティ(翻訳に使われた句の数)に , ある重み  $\lambda$  を掛けたものを利用する . この  $\lambda$  は自動推定する .

もし ,  $\lambda > 0$  なら , 句の数が多いほど翻訳候補のスコアは良くなる .

$\lambda < 0$  なら , 句の数が少ないほど良い .

通常は  $\lambda < 0$  で , 少ない方が良い . これは同じ単語数からなる文であれば , 使われた句の数が少ない (句の長さは長い) 方が良いことになる .

## フレーズ抽出まとめ

発見的手続きをすることにより，日英のフレーズ対応を得て，そこに各種のスコアを付けることができることをみた．

## 問題 (15分)

自動作成したフレーズテーブルには，さまざまな誤りが含まれる．そのようなフレーズテーブルの中から正しそうなフレーズのみを自動抽出するには，どうしたら良いか．

## 回答例 1

	$\bar{f}$	$\bar{f}$ 以外
$\bar{e}$	a	b
$\bar{e}$ 以外	c	d

$a = \bar{e}$  と  $\bar{f}$  の対応数

$b = \bar{e}$  の出現数 -  $a$

$c = \bar{f}$  の出現数 -  $a$

$d = \text{句の対応の総数} - a - b - c$

とすると  $\frac{a}{c} \gg \frac{b}{d}$  のとき,  $\bar{e}$  と  $\bar{f}$  は良い対応と考えられる. これは,  $\bar{e}$  と  $\bar{f}$  の独立性の検定をして, 独立性の低いものが良いということなので, その検定結果により, 独立性の低い順に句対応をソートして, 上位のみを利用する.

## 回答例2

- パラレルコーパスを2つに分ける .
- それぞれのコーパスから 1 つずつフレーズテーブルを作る
- 両方のフレーズテーブルに含まれるようなフレーズのみを採用する

これらの回答例の得失

得 ある程度は信頼性の高いフレーズテーブルができる  
失 カバレッジが低くなる

→ 得が大きいか , 失が大きいかは実験してみないと分からぬ .

今のところ , 翻訳の性能を下げずに , ノイズ除去ができるらしいということが分かっている .