

SRILM 説明

- **SRILM**

SRILM is a toolkit for building and applying statistical language models (LMs), and it runs under Linux/UNIX system.

<http://www.speech.sri.com/projects/srilm/>

Current Version 1.4.3 3 December 2004

- **Cygwin**

Cygwin is a Linux-like environment for Windows.

<http://www.cygwin.com/>

Current Version 1.5.12-1 November 2004

SRILM安裝說明

- Cygwin Setup

step1. 下載 [setup file](http://www.cygwin.com/) from <http://www.cygwin.com/>

step2. 執行setup.exe開始安裝。選擇install from internet。接著一直下一步都不用改，直到要選一個mirror site，選<ftp://ftp.nctu.edu.tw/>會比較快。接著不用改任何設定，直接default安裝就可以了。

step3. 安裝完，執行桌面上的捷徑，會在c:\cygwin\home\username\產生三個檔案，.bash_profile, .bashrc, .inputrc.

step4 .編輯 .bashrc，加入底下幾行:

```
export SRILM=/srilm
export MACHINE_TYPE=cygwin
export PATH=$PATH:$pwd:$SRILM/bin/cygwin
export MANPATH=$MANPATH:$SRILM/man
```

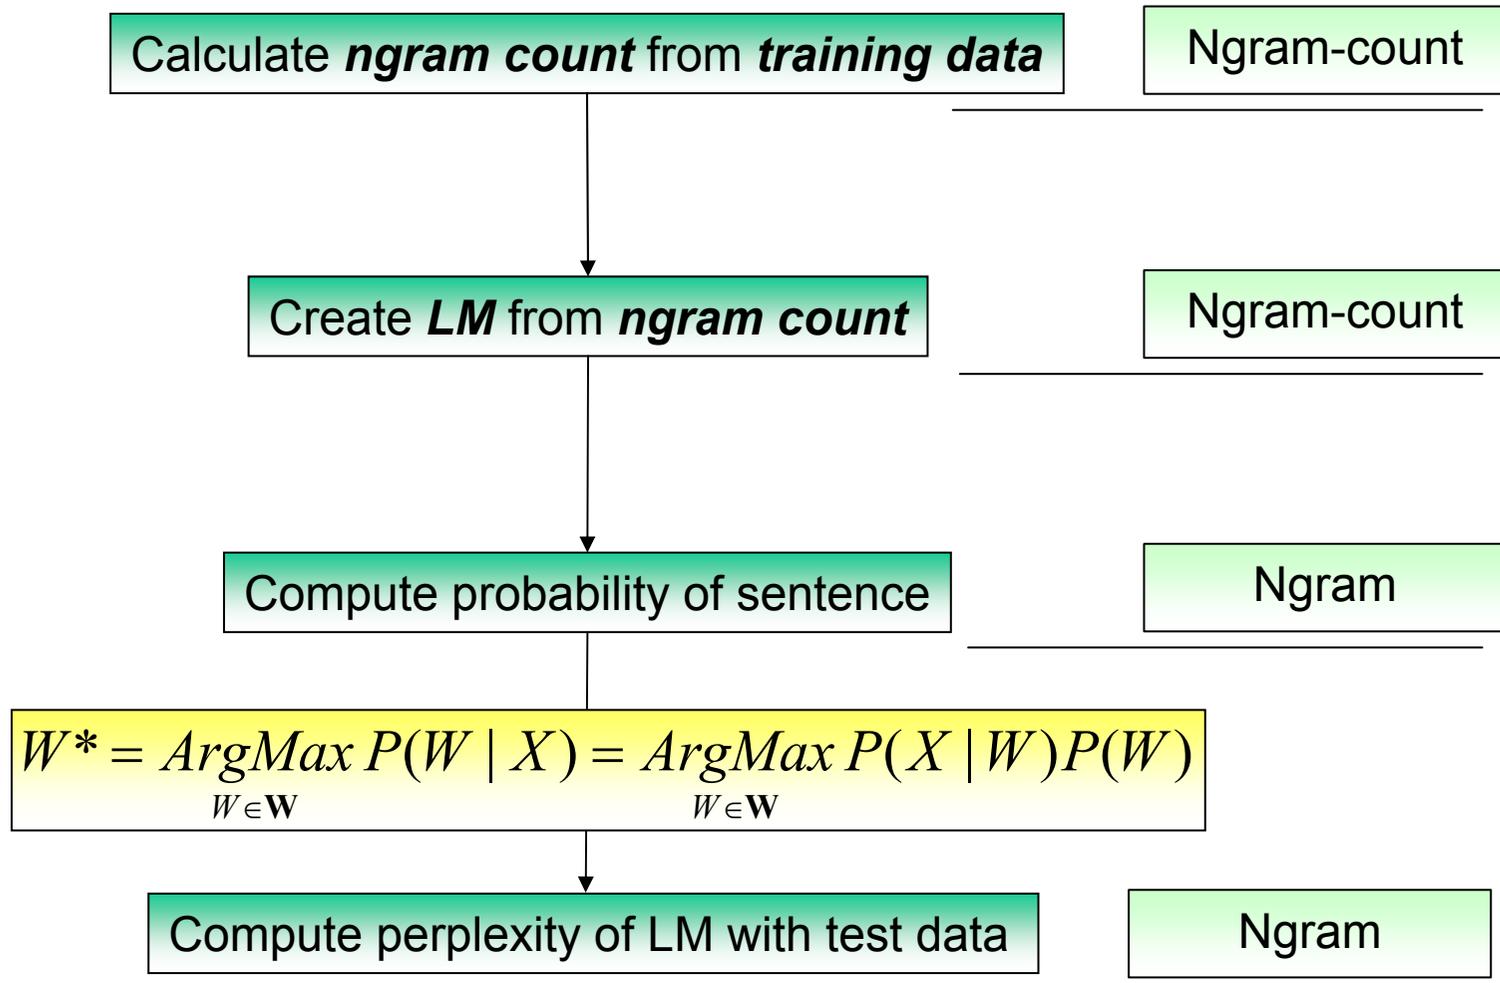
- SRILM Setup

把已經compile過的srilm.rar解壓縮到c:\cygwin\

- 如果要compile source code，cygwin要安裝gcc, g++, make等工具。
- 修改srilm/Makefile 增加一行SRILM=/srilm
- 在srilm目錄下依序執行
make World、make all、make cleanest

詳細資料參考INSTALL、srilm/doc/README.windows

Main Tasks



Training Data Format (CNA0001-2M.Train)

- CNA0001-2M.Train 49.8MB

中華民國八十九年一月一日

中央通訊社新聞

行政院新聞局

局版臺訊字第

一四號中華郵政認為第一類新聞紙類中

華民國十三年四月一日創刊

發行人 行人

汪

萬

Vocabulary Format (Lexicon2003-72k.txt)

巴
八
扒
叭

墨竹
默祝
末梢
沒收
墨守
陌生
莫說

共有 71695 個words

Count

- 計算training data中每個出現的ngram的出現次數

輸出 ngram
count檔

要計算count的
Training data

```
➤ ngram-count -text CNA0001-2M.Train -write  
CNA0001-2M.count -unk -vocab Lexicon2003-72k.txt  
-order 3
```

trigram

有-unk : 把詞典中沒有的詞(oov)當作一個<unk>符號處理

無-unk : 遇到oov就移除

詞典檔

Ngram Count Format

在整個training data中出現的次數

CNA0001-2M.count)

Unigram

想像得到 2
想像得到 </s> 1
想像得到的 1
想像得到的 偶數 1
鳳凰 144

Bigram

鳳凰 優質 1
鳳凰 優質 旅遊 1
鳳凰 </s> 22
鳳凰 城 35
鳳凰 城 </s> 15
鳳凰 城 歐 1

Trigram

鳳凰 城 經商 1
鳳凰 城 機場 1
鳳凰 城 魯 1
鳳凰 城 二十 2
鳳凰 城 的 1
鳳凰 城 第一 1
鳳凰 城 太陽 11

...
學期 有 1
學期 有 1
學期 間 1
學期 間 學校 1
學期 實施 3
學期 實施 到 1
學期 實施 </s> 2
學期 假期 1
學期 假期 辦法 1
學期 開設 1
學期 開設 的 1
學期 國民小學 1
學期 國民小學 校長 1
學期 國民 2
學期 國民 中小學 2
學期 延誤 1
...

Good-Turing Discounting and Katz Backoff

Ngram
count檔

輸出LM
檔

預設的
discounting跟
backoff方法

```
> ngram-count -read CNA0001-2M.count -lm CNA0001-2M_N3.LM.3-7.gt  
-unk
```

```
> ngram -ppl. 506.PureText -lm CNA0001-2M_N3.LM.3-7.gt -unk - order 3  
> NTNU2004hw.ppl
```

輸出ppl結果

要算ppl的
Test data

LM檔

```
file TestText.txt: 1096781 sentences, 4564098 words, 0 OOVs  
0 zeroprobs, logprob= -1.31635e+07 ppl= 211.521 ppl1= 765.86
```

$\frac{\text{logprob}}{10 \text{ 句數+字數}}$

$\frac{\text{logprob}}{10 \text{ 字數}}$

LM Format

(CNA0001-2M_N3.LM.3-7.gt)

最高的ngram沒有backoff weight

```
\data\  
ngram 1=71697  
ngram 2=571216  
ngram 3=578595
```

以\data\開頭

```
\1-grams:  
-0.8422701 </s>  
-99 <s> -1.167359  
-2.07538 — -1.257989  
-4.031029 —— -0.6068805  
-7.448923 —— 恐怖  
-7.448923 —— 恐怖攻擊  
-7.448923 —— 丁點  
-3.339295 —— 九九 -2.965494  
-7.448923 —— 了百了  
-7.448923 —— 刀兩斷  
-4.720053 —— 一下 -0.3730158  
-5.184257 —— 一下子 -0.1966212  
-6.66612 —— 一口咬定
```

Log probability
(Base 10)

Log of backoff
weight (Base 10)

```
-1.227553 德 碁 </s>  
-1.154267 德 碁 半導體  
-1.6313 德 碁 合併  
-1.154267 德 碁 和  
-1.154267 德 碁 的  
-1.227553 德 碁 後  
-1.227553 德 碁 換  
-1.6313 德 碁 普通  
-1.6313 德 碁 對  
-0.7096938 德 碁 與  
-0.1099438 不 銹 鋼  
-0.4164561 <s> 裏 </s>  
-0.1435432 戈 裏 峰  
-0.6717286 那 裏 </s>  
-0.1544242 薩 裏 德  
-0.5066067 化 粧 </s>
```

```
\end\  

```

以\end\結尾

Good-Turing Discounting Default Parameters

自己指定mincount跟maxcount :

```
> ngram-count -read CNA0001-2M.count -lm
CNA0001-2M_N3.LM.3-7.gt -unk --gt1min 1 -
gt1max 7 -gt2min 1 -gt2max 7 -gt3min 1 -gt3max 7
```

1-gram GT parameters

mincount 1
maxcount 1

2-gram GT parameters

mincount 1
maxcount 7

3-gram GT parameters

mincount 2
maxcount 7

maxcount

mincount

$$P_{Katz}(w_i|w_{i-1}) = \begin{cases} C(w_{i-1}w_i)/C(w_{i-1}) & r > k \\ d_r C(w_{i-1}w_i)/C(w_{i-1}) & k \geq r > 0 \\ \alpha(w_{i-1})P(w_i) & r = 0 \end{cases}$$

$$\text{where } d_r = \frac{r^* - \frac{(k+1)n_{k+1}}{n_1}}{1 - \frac{(k+1)n_{k+1}}{n_1}} \text{ and } \alpha(w_{i-1}) = \frac{1 - \sum_{w_i:r>0} P_{Katz}(w_i|w_{i-1})}{1 - \sum_{w_i:r>0} P_{Katz}(w_i)}$$

預設值

Absolute Discounting

```
➤ ngram-count -read CNA1999.count -lm CNA1999.cd5.lm -unk -  
cdiscount1 0.5 -cdiscount2 0.5 -cdiscount3 0.5
```

```
> ngram -ppl CNA1999.test -lm CNA1999.cd5.lm -unk -order 3 >  
CNA1999.cd5.o3.ppl
```

Modified Kneser-Ney Discounting

```
> ngram-count -read CNA1999.count -lm CNA1999.knd.lm -unk -  
kndiscount1 -kndiscount2 -kndiscount3
```

```
> ngram -ppl CNA1999.test -lm CNA1999.knd.lm -unk -order 3 >  
CNA1999.knd.o3.ppl
```

Witten-Bell Discounting

```
> ngram-count -read CNA1999.count -lm CNA1999.wbd.lm -unk -  
wbdiscout1 -wbdiscout2 -wbdiscout3
```

```
> ngram -ppl CNA1999.test -lm CNA1999.wbd.lm -unk -order 3 >  
CNA1999.wbd.o3.ppl
```

Ristad's Natural Discounting

```
> ngram-count -read CNA1999.count -lm CNA1999.nd.lm -unk -  
ndiscount1 -ndiscount2 -ndiscount3
```

```
> ngram -ppl CNA1999.test -lm CNA1999.nd.lm -unk -order 3 >  
CNA1999.nd.o3.ppl
```