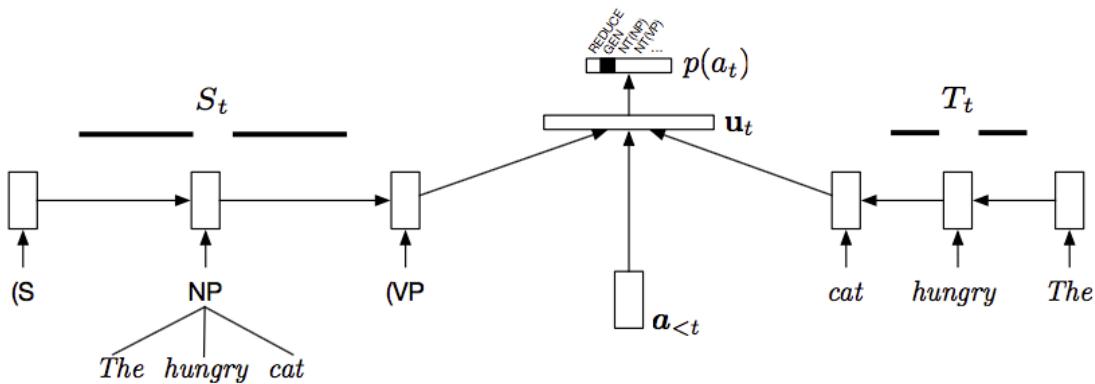


RNNG Code Use Guide

张诗悦 2016.10.14

1. Introduction

RNNG 是用 RNN 做 parsing 以及 language model 的模型，基本的模型结构如下图所示。RNNG 包含两个 model：discriminative model 是做句法树的预测，generative model 是做句子的生成。具体内容请参见 Chris Dyer 等在 NAACL 2016 上发表的论文：Recurrent Neural Network Grammars。



这篇文档的主要内容是简单介绍 RNNG 代码的使用。RNNG 的代码来源为：
<https://github.com/clab/rnng>，该代码库中也有介绍相关的使用方法，而这篇文档将更加详细地介绍具体的操作步骤，以及适用于我们实验室服务器的参数配置。

以下的说明均在 wolf08 机器上得到正确测试，如换用机器可能会出现其他问题。
一些生成文件的步骤读者可以省略，直接在 /work4/zhangsy/rnng 目录下寻找生成好的文件即可。因为纯属个人经验，错误和缺失的地方，还请批评指正。

2. Prepare Code

这部分将介绍在正确运行 RNNG 之前的一些代码准备，包括配置一些依赖库和以及编译代码。

2.1 Boost

RNNG 代码中依赖 C++ 的 Boost 库，需要在本地配置一个 Boost 库。配置步骤如下：

1. 从 <https://sourceforge.net/projects/boost/files/boost/> 上下载 boost 库，版本选择应该没有太大影响，我采用的是 1.61。将下载得到的压缩包，放到自己的根目录，解压。
2. 编译 b2：执行 `./bootstrap --prefix=[要安装到的目录，默认为当前目录，例如：/work4/zhangsy/boost_1_61_0]`。
3. 编译 boost：执行 `./b2` (或者执行 `./bjam`)

4. 测试是否配置成功：将下面这段代码写入 test.cc 文件，执行命令 `g++ -o test test.cc -I [boost 的安装目录]`, 例如: `/work4/zhangsy/boost_1_61_0` -L [boost lib 目录], 例如: `/work4/zhangsy/boost_1_61_0/stage/lib`。如果成功运行输出，则说明配置成功。

```
#include <iostream>
#include <boost/timer.hpp>
using namespace std;
int main()
{
    boost::timer t;
    cout << "max timespan:" << t.elapsed_max() / 3600 << "h" << endl;
    cout << "min timespan:" << t.elapsed_min() << "s" << endl;
    cout << "now time elapsed:" << t.elapsed() << "s" << endl;
    return 0;
}
```

2.2 Eigen

从 <https://bitbucket.org/eigen/eigen/downloads> 上下载最新版本的 eigen, 无需安装, 只需要把解压后的文件夹, 放在根目录(e.g. `/work4/zhangsy/`)下即可。

2.3 RNNG

这一部分将介绍如何编译 RNNG 的代码, 步骤如下：

1. 下载 RNNG 代码库：[git clone https://github.com/clab/rnng.git](https://github.com/clab/rnng.git)
2. 修改 CMakeLists.txt: 在原始的 CMakeLists.txt 中添加下面四句话, 其中对应的路径换成读者设置的 Boost 和 eigen 的目录路径即可。

```
SET(BOOST_ROOT "/work4/zhangsy/boost_1_61_0")
SET(Boost_INCLUDE_DIR "/work4/zhangsy/boost_1_61_0")
SET(Boost_LIBRARIES "/work4/zhangsy/boost_1_61_0/stage/lib")
SET(EIGEN3_INCLUDE_DIR "/work4/zhangsy/eigen")
```

3. 执行下面的命令：

```
mkdir build
cd build
cmake ..
make -j 2
```

4. 在 rnng 下执行命令：`./build/nt-parser/nt-parser -h`, 如果正确输出模型的配置参数说明, 则说明编译成功。

2.4 EVALB

RNNG 中在做准确率的计算的时候会用到EVALB模块, 从 <http://nlp.cs.nyu.edu/evalb/> 上下载EVALB.tgz, 解压后, 放在rnng目录下即可。

3. Prepare Data

经过以上 4 步, 基本将代码准备好了, 然而在运行之前我们还需要将数据准备好。如论文中所说, 使用 Penn Treebank §2–21 作为训练集, §24 作为验证集, §23 作为测试集。在 `/work4/zhangsy/rnng/wsj` 目录下是 Penn Treebank 的 00–24 的数据。

3.1 Preprocess

在 wsj 目录下的数据是分离的, 而且格式是树状的, 这一步将数据整合起来, 并按照每个句法树一行来存储。

1. 在 mng 目录下新建 preprocess.py 文件，写入如下内容：

```
import os
import sys

def convert_to_one_line(file):
    lines = open(file, 'r').read().split('\n')
    sens = []
    sen = ""
    for line in lines:
        if line:
            if line[0] == '(' and sen:
                sen = sen[1:-2].strip() + '\n'
                sens.append(sen)
                sen = ""
            line = line.strip()
            if line:
                sen += '{}'.format(line)
    if sen:
        sen = sen[1:-2].strip() + '\n'
        sens.append(sen)

    return ''.join(sens)[-1]

def convert(wsj):
    dirs_map = {
        "train": ['02', '03', '04', '05', '06', '07', '08', '09', '10', '11', '12', '13', '14', '15', '16', '17', '18',
                  '19', '20', '21'],
        "dev": ['24'],
        "test": ['23']
    }
    for dataset in ['train', 'dev', 'test']:
        dirs = dirs_map[dataset]
        with open("{}_all".format(dataset), 'a') as f:
            for dir in dirs:
                dir = "{}{}".format(wsj, dir)
                files = sorted(os.listdir(dir))
                for file in files:
                    f.write(convert_to_one_line("{}{}".format(dir, file)) + '\n')

def extract_unk_lines(file):
    """
    extract the lines contain 'UNK' in train.oracle to train.txt, which will be used in cluster
    """
    f = open(file, 'r')
    lines = f.read().split('\n\n')[-1]
    f.close()
    for line in lines:
        items = line.split('\n')
        print items[4]

def extract_stemmed_trees(file):
    """
    extract the lines of stemmed trees in *.oracle to *.stem, which will be used in evaluation
    """
    lines = open(file).read().split('\n')
    for line in lines:
        if len(line) > 1 and line[0] == '#':
            print line[2:]

if __name__ == '__main__':
```

```

if len(sys.argv) < 2:
    print "please input wsj dir!"
    exit()
convert(sys.argv[1])

```

2. 执行命令 `python2 preprocess.py /work4/zhangsy/rnng/wsj`, 在 rnng 目录下得到 train.all, dev.all, test.all 三个文件。

3. 在 rnng 下新建 data 文件夹, 将三个文件移动到 data 目录下。

4. 一个需要处理的小细节 : 在 train.all 中有一行是

```
(NP (NP (QP (# #) (CD 200) (CD million) ) (-NONE- *U*)) (PP (IN of) (NP (NP (JJ undated) (JJ variable-rate) (NNS notes) ) (VP (VBN priced) (NP (-NONE- *)) (PP-CLR (IN at) (NP (JJ par) )) (PP (IN via) (NP (NNP Merill) (NNP Lynch) (NNP International) (NNP Ltd) ))))) (. .) )
```

这行句子的第一个词是#, 会影响之后的操作, 因此把第一个词删除, 改为:

```
(NP (NP (QP (CD 200) (CD million) ) (-NONE- *U*)) (PP (IN of) (NP (NP (JJ undated) (JJ variable-rate) (NNS notes) ) (VP (VBN priced) (NP (-NONE- *)) (PP-CLR (IN at) (NP (JJ par) )) (PP (IN via) (NP (NNP Merill) (NNP Lynch) (NNP International) (NNP Ltd) ))))) (. .) )
```

3.2 Format

模型的输入数据需要有一定的格式, 对于 discriminative model 的数据每个句子需要被表示成五部分 : 句法树, 原始的句子, 小写的句子, 加入 unknown 词的句子, actions ; 对于 generative model 的数据每个句子需要被表示成四部分 : 句法树, 原始句子, 加入 unknown 词的句子, actions。步骤如下 :

1. 修改 rnng 下的 get_oracle.py 和 get_oracle_gen.py 两个代码。因为我使用的数据中 nonterminal tokens 种类较多, 需要做一个 stemming 的工作, 将类似 “NP-SBJ” 这样的 nonterminal token 中 ’ - ‘ 后的部分去掉, 变成 “NP” 。修改后的代码为 /work4/zhangsy/rnng 目录下的 get_oracle_stem.py 和 get_oracle_gen_stem.py。

2. 执行如下 6 个命令 :

```
python get_oracle_stem.py data/train.all data/train.all > data/train.oracle
```

```
python get_oracle_stem.py data/train.all data/dev.all > data/dev.oracle
```

```
python get_oracle_stem.py data/train.all data/test.all > data/test.oracle
```

```
python get_oracle_gen_stem.py data/train.all data/train.all > data/train_gen.oracle
```

```
python get_oracle_gen_stem.py data/train.all data/dev.all > data/dev_gen.oracle
```

```
python get_oracle_gen_stem.py data/train.all data/test.all > data/test_gen.oracle
```

3. 将 dev.oracle 和 test.oracle 中的句法树 (也就是每个句子的第一行去除#) 单独输出到文件 dev.stem 和 test.stem, 以备后续之用。代码参见 preprocess.py 中的 extract_stemmed_trees 函数。

3.3 Word cluster

在 generative model 中需要用到词的聚类, 论文中采用的是 Brown Cluster。这里简单介绍如何生成聚类文件 :

1. 将 train.oracle 中, 带有’ UNK’ 的句子 (也就是每个句子的第四种表示), 单独输出到文件 train.txt。代码参见 preprocess.py 中的 extract_unk_lines 函数。

2. 下载 brown-cluster 代码库 `git clone https://github.com/percyliang/brown-cluster.git`, 执行 make 命令编译代码。

3. 在 brown-cluster 目录下，执行命令 `./wcluster --text train.txt --c 156`，其中 156 是类别的个数，等于 \sqrt{V} ， V 是词的个数。

4. 输出的文件为 `train-c156-p1.out/paths`，将其重命名为 `word_clusters.txt`，放在 rnng/data 目录下备用。

4. Discriminative Model

Discriminative model 是预测句法树的模型，模型最终输出的是预测到的句法树。可以认为模型建模的是给定句子，句法树的条件概率 $p(y|x)$ 。rnng/nt-parser 目录下的 nt-parser.cc 为 discriminative 模型的代码。

4.1 Modify

在运行代码之前，为了适应我们服务器的配置，需要对 nt-parser.cc 代码作出一些修改：

1. 将 `"/tmp/parser_dev_eval."` 改为 `"tmp/parser_dev_eval."`，并在 rnng 目录下新建一个 tmp 目录。

2. 将 `python remove_dev_unk.py` 改为 `python2 remove_dev_unk.py`。

3. 重新编译代码，执行命令：

```
cd build  
make -j 2
```

4.2 Configuration

模型的输入参数有如下：

```
Configuration options:  
-T [ --training_data ] arg          List of Transitions – Training corpus  
-x [ --explicit_terminal_reduce ]    [recommended] If set, the parser must  
                                     explicitly process a REDUCE operation to  
                                     complete a preterminal constituent  
  
-d [ --dev_data ] arg                Development corpus  
-C [ --bracketing_dev_data ] arg     Development bracketed corpus  
-p [ --test_data ] arg               Test corpus  
-D [ --dropout ] arg                Dropout rate  
-s [ --samples ] arg                 Sample N trees for each test sentence  
                                     instead of greedy max decoding  
-a [ --alpha ] arg                  Flatten ( $0 < \alpha < 1$ ) or sharpen ( $1 < \alpha$ ) sampling distribution  
-m [ --model ] arg                 Load saved model from this file  
-P [ --use_pos_tags ]               make POS tags visible to parser  
--layers arg (=2)                   number of LSTM layers  
--action_dim arg (=16)              action embedding size  
--pos_dim arg (=12)                POS dimension  
--input_dim arg (=32)              input embedding size  
--hidden_dim arg (=64)             hidden dimension  
--pretrained_dim arg (=50)          pretrained input dimension  
--lstm_input_dim arg (=60)          LSTM input dimension  
-t [ --train ]                      Should training be run?  
-w [ --words ] arg                 Pretrained word embeddings  
-b [ --beam_size ] arg (=1)         beam size  
-h [ --help ]                       Help
```

4.3 Train

训练 discriminative model，执行下面的命令：

```
./build/nt-parser/nt-parser -x -T data/train.oracle -d data/dev.oracle -C data/dev.stem -P -t --  
input_dim 128 --lstm_input_dim 128 --hidden_dim 128 -D 0.2
```

模型训练过程不会主动停止，需要人工停止。训练过程中每次 update 100 个句子，约耗时 100ms 左右，每隔 15 次 update 会在验证集上评估一次效果，输出预测的 F1 值。如果 F1 值大于最好的 F1 值，则将这次的模型存入 ntparse_XXX-pidXXX.params 文件中。大约需要跑 11 轮以上可以达到比原论文更好的效果。

4.4 Test

测试 discriminative model，执行下面的命令，参见/work4/zhangsy/rnng/test.sh：

```
.build/nt-parser/nt-parser -x -T data/train.oracle -d data/dev.oracle -C data/test.stem -m latest_model -P -p data/test.oracle --input_dim 128 --lstm_input_dim 128 --hidden_dim 128 -D 0.2
```

注意-m 参数可以设置最佳模型的*.params 文件，也可以设置为指向最佳模型的软链接 latest_model。测试最终会输出在测试集上的 F1 值，最佳可达到 92.26 左右。

5. Generative Model

Generative model 是生成模型，在预测 action 的同时要生成词。可以认为模型建模的是句子和句法树之间的联合概率 $p(x,y)$ 。

5.1 Modify

在运行代码之前，需要对原始的代码作出一些修改：

1. 将 latest_model 改为 latest_model_gen

2. 重新编译代码，执行命令：

```
cd build  
make -j 2
```

5.2 Configuration

模型的输入参数有如下：

Configuration options:	
-T [--training_data] arg	List of Transitions – Training corpus
-x [--explicit_terminal_reduce]	[not recommended] If set, the parser must explicitly process a REDUCE operation to complete a preterminal constituent
-D [--dropout] arg	Use dropout
-c [--clusters] arg	Clusters word clusters file
-d [--dev_data] arg	Development corpus
-p [--test_data] arg	Test corpus
-e [--eta_decay] arg	Start decaying eta after this many epochs
-m [--model] arg	Load saved model from this file
--layers arg (=2)	number of LSTM layers
--action_dim arg (=16)	action embedding size
--input_dim arg (=32)	input embedding size
--hidden_dim arg (=64)	hidden dimension
--pretrained_dim arg (=50)	pretrained input dimension
--lstm_input_dim arg (=60)	LSTM input dimension
-t [--train]	Should training be run?
-w [--words] arg	Pretrained word embeddings
-h [--help]	Help

5.3 Train

训练 generative model，执行下面的命令：

```
./build/nt-parser/nt-parser-gen -x -T data/train_gen.oracle -d data/dev_gen.oracle -c  
data/word_clusters.txt -t --input_dim 256 --lstm_input_dim 256 --hidden_dim 256 -D 0.3
```

模型训练过程不会主动停止，需要人工停止。训练过程中每次 update 100 个句子，约耗时 300ms 左右，每隔 100 次 update 会在验证集上评估一次效果，输出在验证集上的 ppl。如果 ppl 值小于最好的 ppl 值，则将这次的模型存入 ntparse_gen_XXX-pidXXX.params 文件中。大约需要跑 16 轮以上可以达到比原论文更好的效果。

5.4 Test

由于生成模型建模的是联合概率 $p(x, y)$ ，为了评估其准确率和作为 language model 的效果，都要求出边缘概率 $p(x)$ 。因此采取先从 discriminative model 中采样，在利用 generative model 重新排序的方法。具体请见原论文。步骤如下：

1. 从 discriminative model 中采样，对每个在测试集中的句子采样 100 个预测出的句法树，执行下面的命令：

```
./build/nt-parser/nt-parser -x -T data/train.oracle -d data/dev.oracle -C data/test.stem -m  
latest_model -P -p data/test.oracle --input_dim 128 --lstm_input_dim 128 --hidden_dim 128 -  
D 0.2 -s 100 -a 0.8 > test-samples.props
```

2. 去除 test-samples.props 中每一行的多余部分，执行命令 `utils/cut-corpus.pl 3 test-samples.props > test-samples.trees`

3. 从生成模型中获得联合概率，执行命令：

```
./build/nt-parser/nt-parser-gen -x -T data/train_gen.oracle --clusters data/word_clusters.txt -  
-input_dim 256 --lstm_input_dim 256 --hidden_dim 256 -p test-samples.trees -m  
latest_model_gen > test-samples.likelihoods
```

4. 获得边缘概率，执行命令：

```
utils/is-estimate-marginal-lh.pl 2416 100 test-samples.props test-samples.likelihoods >  
lh.txt 2> rescored.trees
```

5. 执行以下四个命令：

```
utils/add-fake-preterms-for-eval.pl rescored.trees > rescored.preterm.trees  
utils/replace-unks-in-trees.pl data/test.oracle rescored.preterm.trees > hyp.trees  
python2 utils/remove_dev_unk.py data/test.stem hyp.trees > hyp_final.trees  
EVALB/evalb -p EVALB/COLLINS.prm data/test.stem hyp_final.trees > parsing_result.txt
```

6. 以上命令可以集合成一个脚本，参见/work4/zhangsy/rnng/test-gen.sh。

lh.txt 文件中的最后几行会给出 language model 中边缘概率 $p(x)$ 的 perplexity，大约可以达到 88.66。parsing_result.txt 中给出了 generative model 的准确率，F1 值大约为 92.88。

6. Reference

- [1] Dyer C, Kuncoro A, Ballesteros M, et al. Recurrent Neural Network Grammars[J]. 2016.
- [2] <https://github.com/clab/rnng>