

D:\myprojects\nlp\rnn\rnn_m21.py

```
1 # Many-to-one (2-to-1) RNN 예
2
3 ##### conda create -n word2vec nltk pandas
4 # conda activate word2vec
5 ##### conda install pytorch torchvision torchaudio pytorch-cuda=12.1 -c pytorch -c nvidia
6 # 또는 conda install pytorch torchvision torchaudio cpuonly -c pytorch
7 # (word2vec) python rnn_m21.py train 500 # 학습시
8 # (word2vec) python rnn_m21.py i love # Prediction 시
9
10 import numpy as np
11 import nltk
12 import torch, sys
13 import torch.nn as nn
14 import torch.optim as optim
15 import torch.nn.functional as F
16 from tqdm import tqdm
17
18 #=====
19 # Input Target batch 데이터 생성 함수
20 # #=====
21 def make_batch(sentences, forTrain=True):
22     input_batch = []
23
24     if forTrain :
25         target_batch = []
26
27         for sen in sentences:
28             words = sen.split()
29             input = [word_dict[n] for n in words[:-1]]
30             target = word_dict[words[-1]]
31
32             # input번째 자리만 1이 되게 One-Hot Encoding
33             # input list 가 2개 값만 가지면 아래는 2개의 one-hot vectors 생성
34             input_batch.append(np.eye(n_class)[input])
35
36             target_batch.append(target)
37
38         return input_batch, target_batch
39
40     else : # for Prediction
41         sentence = sentences
42
43         words = sentence.split()
44         #print(f'words: {words}')
45         input = [word_dict[n] for n in words[:-1]]
46
47         input_batch.append(np.eye(n_class)[input]) # One-Hot Encoding
48
49         return input_batch
50
51
52 #=====
53 # windows data creation
54 #=====
55 def make_windows(cleaned_sentences, windowSize=2) :
56     MASK_TOKEN = "<MASK>"
57
```

```

58         # 각 문장의 토큰 리스트를 순회하면서 지정된 크기(길이 5개)의 window로 묶어주기
59         # lambda 매개변수 : 표현식의 예:
60         # matrix = [[1, 2], [3, 4], [5, 6]]
61         # squared = [num ** 2 for row in matrix for num in row]
62         # print(squared) # Output: [1, 4, 9, 16, 25, 36]
63         # 2차원-->1차원으로 펴기
64         flatten = lambda outer_list: [item for inner_list in outer_list for item in inner_list]
65         # nltk.ngrams([1,2,3,4,5], 3)) ==> [(1, 2, 3), (2, 3, 4), (3, 4, 5)]
66         # 전체 cleaned_sentences로부터,
67
68         # cleaned_sentences로부터 가져온 각 문장에서 5개의 단어(토큰)로 이루어진 windowx
리스트를 가져와라
69
70         # cleaned_sentences에서 sentence를 하나씩 가져와서 nltk.ngram을 통해
71         # sentence 맨 앞과 맨 뒤에 각각 2개씩의 <MASK> 토큰을 추가한 후, 5개 단어 길이의
wind리스트로
72         # 바꾼 후, flatten 하라
73         # I iove you --> [<MASK>, <MASK>, 'I', 'love', 'you', <MASK>, <MASK>]
74         windows = flatten(nltk.ngrams(sentence[:-windowSize].split(' '), windowSize + 1) \
75                             for sentence in tqdm(cleaned_sentences))
76
77         return windows
78
79 #=====
80 # TextRNN Class
81 #=====
82 class TextRNN(nn.Module):
83     forward_pass = 0
84
85     def __init__(self):
86         super(TextRNN, self).__init__()
87
88         # dropout 옵션은 hidden layer갯수가 1 초과일때만 사용
89         #self.rnn = nn.RNN(input_size=n_class, hidden_size=n_hidden, dropout=0.3)
90
91         # input_size=n_class : 입력값을 클래스 크기만큼 길이의 one-hot vector로 할거니까
92         # hidden_size : hidden layer node 수 = 5 로 미리 정함
93         self.rnn = nn.RNN(input_size=n_class, hidden_size=n_hidden)
94         # trainable weight matrix initialized with random values
95         # nn.Parameter() : 해당 파라미터가 학습시에 참여하는 weight가 됨
96         self.W = nn.Parameter(torch.randn([n_hidden, n_class]).type(dtype)) # n_hiddex *
n_class 크기 matrix
97         # n_class 크기 bias용 vector
98         self.b = nn.Parameter(torch.randn([n_class]).type(dtype))
99         # raw 출력값들에 적용할 함수
100         self.Softmax = nn.Softmax(dim=1)
101
102     def add_count (self, n=1):
103         self.forward_pass += n
104
105     def reset_count (self):
106         self.forward_pass = 0
107
108         # X : 입력 시퀀스에서의 변하는 X값
109         # hidden : 계속 update 되는 hidden matrix 값
110         # 이 forward 함수는 epoch 횟수만큼 호출,
111     def forward(self, hidden, X):
112         # input tensor to have a shape of (seq_len, batch, feature),
113         # batch와 seq_length 위치를 교체
114         # 이 예제의 경우 (seq_len, batch_size, hidden_size)형식으로 리턴되는데
115         # (2, 11, 5) 크기가 됨
116         X = X.transpose(0, 1)

```

```

116         # hidden_vectors: 각 time step 마다의 hidden vector 노드들의 값(h(t))을 저장
117         #             나중에 back-propagation시에 gradient 값 계산을 위하여 저장해 둠
118         #             (seq_len, batch, hidden_size) = (2, 11, 5)
119         # hidden : 마지막 time step 직후의 hidden vector 값
120         #             hidden layer가 다층일 경우에는 layer 층의 갯수 만큼 값을 가짐
121
122
123         # 한번의 호출로 한 batch, 모든 시퀀스, 모든 히든벡터에 대한 벡터값들을 리턴
124         #     2 시퀀스 * 11 batch * 5 vector nodes 값을
125         hidden_vectors, hidden = self.rnn(X, hidden)    # 입력층 batch 값들과 히든 벡터를 이용
하여
126                                                         # 히든 벡터 값들을 계산
127         print(f'\n*** hidden_vectors[{self.forward_pass}]: {hidden_vectors}')
128         print(f'\n*** hidden[{self.forward_pass}]: {hidden}')
129
130         last_hidden_vector = hidden_vectors[-1]    # many-to-one 모델이므로 hidden 노드중 마지막
노드값만 필요
131
132         # torch.mm() : matrix multiplication, 실제 계산 출력값을 여기서 리턴
133         model = torch.mm(last_hidden_vector, self.W) + self.b
134
135         self.add_count(1)
136
137         return model
138
139     def print_output_softmax(self, output):
140         softmax_values = self.Softmax(output)
141         print("\n*** Softmax Results:", softmax_values)
142
143     #=====
144     # Rnn Training 함수
145     #=====
146     def train_rnn(totalEpoch) :
147         criterion = nn.CrossEntropyLoss() # 손실함수를 CrossEntropy로 선택
148         optimizer = optim.Adam(model.parameters(), lr=0.01) # Optimizer를 Adam으로 선택
149
150         #-----학습 500회
151         for epoch in tqdm(range(totalEpoch)):
152             # requires_grad=True: backpropagation시에 gradients 누적하라
153             # back propagation 시에 batch_size * sequence_length 만큼 gradient를 계산 및 반
영하도록
154             #     hidden vector들의 변수가 필요 (0으로 초기화)
155             hidden = torch.zeros(1, batch_size, n_hidden, requires_grad=True)
156
157             output = model(hidden, input_batch)
158
159             #if epoch == totalEpoch-1 :
160             print(f'\n*** Epoch # {epoch}일 때 학습 직후 배치데이터 전체에 대한 output layer 출력값
output:\n{output}')
161             print('-'*80)
162
163             loss = criterion(output, target_batch)
164
165             if totalEpoch <= 3 or (epoch % 100) == 0:
166                 print('Epoch:', '%04d' % (epoch), 'cost =', '{:.6f}'.format(loss))
167
168             optimizer.zero_grad()
169             loss.backward()
170             optimizer.step()
171
172     #=====

```

```

173 # [1] Word Processing
174 #=====
175 sentences = ["i like dogs", "i love coffee", "i hate milk", "i enjoy tea",
176             "you like cats", "you love milk", "you hate coffee", "you want snowing",
177             "he expects promotion", "he wants money", "he waits snowing"]
178 windowSize = 2
179 dtype = torch.float
180
181 word_list = list(set(" ".join(sentences).split()))
182 word_list.sort()    # 매 실행시마다 동일한 word index 번호를 갖게
183
184 word_dict = {w: i for i, w in enumerate(word_list)}
185 print('\n', '='*80)
186 print("word dictionary:", word_dict, '\n')
187 number_dict = {i: w for i, w in enumerate(word_list)}
188 n_class = len(word_dict)
189
190 #=====
191 # [2] Input, Target batch data 생성
192 #=====
193     # sentence 문장들로 부터 입력tensor, 출력tensor 구함
194 input_batch, target_batch = make_batch(sentences, True)
195 input_batch = torch.tensor(np.array(input_batch), dtype=torch.float32, requires_grad=True)
196 print('\n', '='*80)
197 print("학습용 input batch:", input_batch)
198
199 target_batch = torch.tensor(target_batch, dtype=torch.int64)
200 print('\n', '='*80)
201 print("학습용 target batch:", target_batch)
202
203 #=====
204 # [3] TextRNN model 생성 및 학습
205 #=====
206     # 저장해야할 hidden matrix의 줄 수는 입력 시퀀스 길이와 같아야 한다
207     # 왜냐하면 "입력시퀀스 크기"="batch_size" 이고, batch 회수 만큼의 입력 후에
208     gradient를 업데이트 하니까
209 batch_size = len(sentences)
210 n_hidden = 5 # 은닉층의 길이
211 model = TextRNN() # rnn 모델 객체 생성
212
213 #=====
214 # main
215 #=====
216 if __name__ == "__main__":
217     print('\n', '='*80)
218     print('\nUsage [학습]: python rnn_m21.py train 100')
219     print('Usage [Prediction]: python rnn_m21.py word1 word2\n')
220     # [4] textRNN 모델 학습
221     if len(sys.argv) >= 3:
222         #----- 학습
223         if 'train' in sys.argv[1] and int(sys.argv[2]) > 0:
224             train_rnn(int(sys.argv[2]))
225
226         # -----
227         # 전체 학습 문장에 대해 prediction 해보기
228         # 전체 문장에 대해 입력 벡터 생성
229         # -----
230         print('\n', '='*80)
231         print('학습 완료 했으니, 전체 입력 데이터에 대해, prediction으로 학습 결과 확인')
232         model.reset_count() # hidden_vectors 의 출력 index를 0으로 reset

```

```

232     input = [sen.split()[:2] for sen in sentences]
233
234     # hidden layer 값 초기화
235     # 1 : hidden layer 수
236     # batch_size : 저장할 hidden matrix의 행, 즉, backward propagation 대상이 되는
time 수
237     # n_hidden : hidden matrix의 열, 즉 hidden vector 한개의 노드 수
238     hidden = torch.zeros(1, batch_size, n_hidden, requires_grad=True)
239     # input 값에 대한 prediction 실행
240     predict = model(hidden, input_batch).data.max(1, keepdim=True)[1]
241     # 결과 출력
242     print('\n', '.'*80, '\n[학습후 테스트 결과]\n')
243     print([sen.split()[:2] for sen in sentences], '->', [number_dict[n.item()] for n in
predict.squeeze()])
244     # 학습 결과 파일로 저장
245     torch.save(model.state_dict(), 'text_rnn.pth')
246
247     else :
248         #----- 매개변수 문장에 대해 Prediction
249         queryStr = sys.argv[1] + ' ' + sys.argv[2] + ' ' + sys.argv[2]
250         sentence = []
251         sentence.append(queryStr)
252
253         #query_input_batch = make_batch(sentence, False)
254         query_input_batch = make_batch(queryStr, False)
255         query_input_batch = torch.tensor(np.array(query_input_batch), dtype=torch.float32,
requires_grad=False)
256
257         print('\n', '-'*80)
258         print("*** Prediction용 input batch:\n", query_input_batch, '\n')
259
260         model = TextRNN() # Initialize the model the same way you did before
261         model.load_state_dict(torch.load('text_rnn.pth')) # 저장된 파일로 부터 모델 및 파라미
터 불러오기
262         model.eval()
263
264         hidden = torch.zeros(1, 1, n_hidden, requires_grad=False)
265         # input 값에 대한 prediction 후 output layer 출력값(softmax값) 출력해보기
266         output = model(hidden, query_input_batch)
267         model.print_output_softmax(output) # 참고로 출력값 찍어보기
268         # 답만 가져오기
269         #predict = model(hidden, query_input_batch).data.max(1, keepdim=True)[1]
270         predict = output.data.max(1, keepdim=True)[1]
271         # 결과 출력
272         print('\n', '-'*80)
273         print(f'전체 sentences : {sentences}\n')
274         print('\n', '-'*80)
275         print(f'predict 결과:{predict}')
276         print(f'*** {sys.argv[1]} {sys.argv[2]} ==> {number_dict[predict.item()]}')
277
278
279
280

```