

第10章

翻訳モデル

13T4054L 根岸 睦

Encoder-Decoder 翻訳モデル

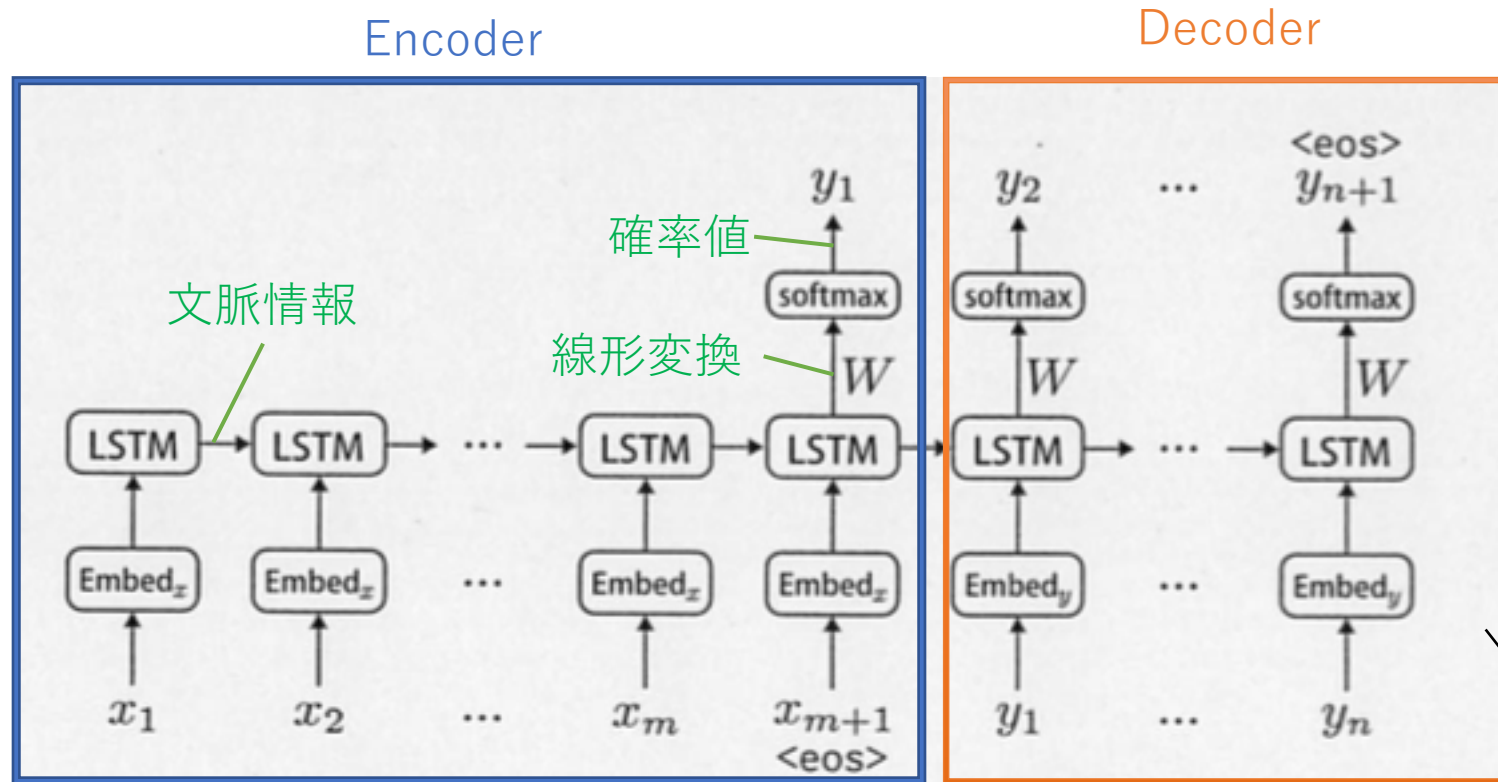


図 10.3 Encoder-Decoder 翻訳モデルの詳細図

目的

原言語 x_1, x_2, \dots, x_m

変換

目的言語 y_1, y_2, \dots, y_n

学習の際は正解の単語 t と出力の単語 y との損失を累積してゆき誤差逆伝播を行う

対訳データの準備

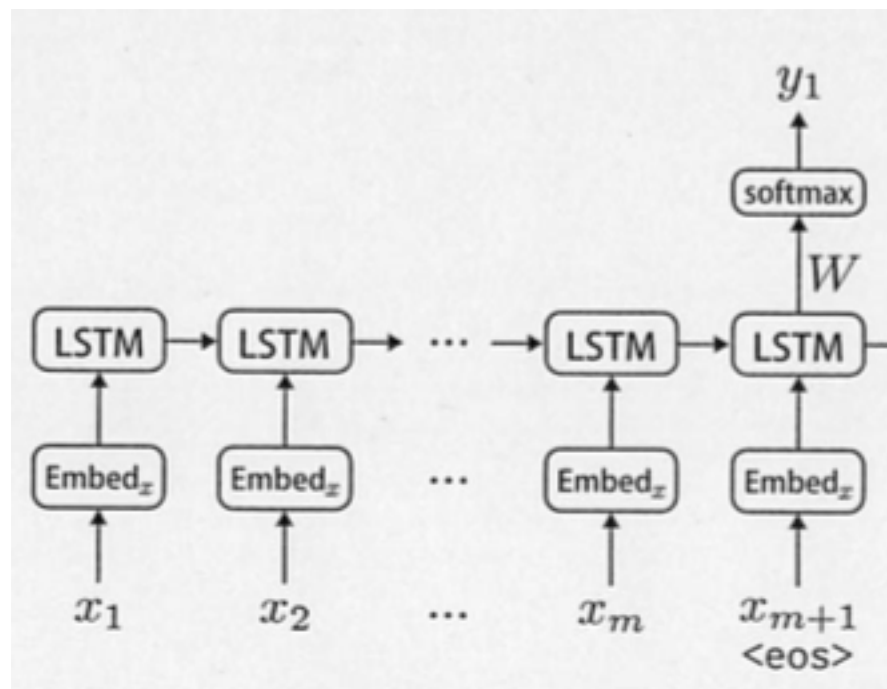
```
# 単語 -> IDの辞書 (日本語)
jvocab = {}
jlines = open('jp.txt').read().split('\n')
for i in range(len(jlines)):
    lt = jlines[i].split()
    for w in lt:
        if w not in jvocab:
            jvocab[w] = len(jvocab)
jvocab['<eos>'] = len(jvocab)
jv = len(jvocab)

# 単語 <--> IDの辞書 (英語)
evocab = {}
id2wd = {}
elines = open('eng.txt').read().split('\n')
for i in range(len(elines)):
    lt = elines[i].split()
    for w in lt:
        if w not in evocab:
            id = len(evocab)
            evocab[w] = id
            id2wd[id] = w
id = len(evocab)
evocab['<eos>'] = id
id2wd[id] = '<eos>'
ev = len(evocab)
```

- 日本語 → 英語 の翻訳
- jlines、elines : 各行のデータが入っているリスト
- jvocab、evocab: 単語をIDに直す辞書
- id2wd: ID から単語に直す辞書 (出力側の英語のみ)

Chainのモデル部分

Encoder

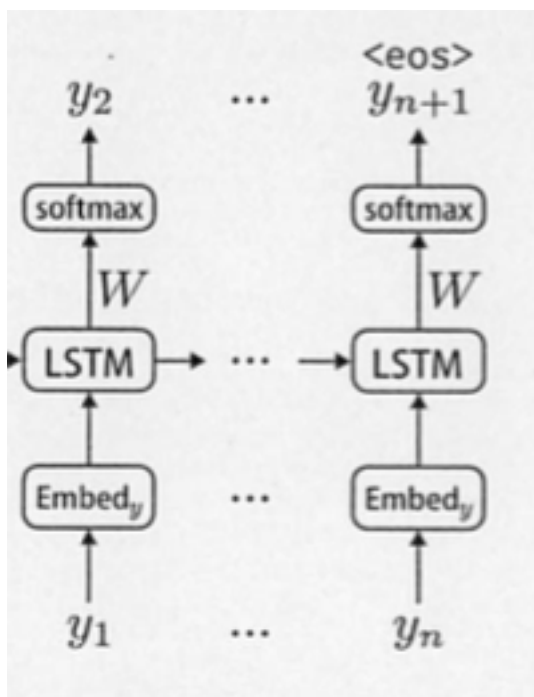


```
# Encoder側
self.H.reset_state()
for i in range(len(jline)):
    wid = jvocab[jline[i]]
    # embedding
    x_k = self.embedx(Variable(\
        np.array([wid], dtype=np.int32)))
    # 文脈情報保持
    h = self.H(x_k)
    # <eos>embedding
    x_k = self.embedx(Variable(\
        np.array([jvocab['<eos>']], dtype=np.int32)))
    # 正解
    tx = Variable(np.array([evocab[eline[0]], \
        dtype=np.int32]))

    h = self.H(x_k)
    # 損失
    accum_loss = F.softmax_cross_entropy(self.W(h), tx)
```

Chainのモデル部分

Decoder



```
# Decoder側
```

```
for i in range(len(eline[i])):
    wid = evocab[eline[i]]
    x_k = self.embedy(Variable(np.array([wid], \
                                     dtype=np.int32)))

    next_wid = evocab['<eos>'] \
               if (i == len(eline) - 1) \
               else evocab[eline[i+1]]
    tx = Variable(np.array([next_wid], \
                           dtype=np.int32))

    h = self.H(x_k)
```

```
# 損失の累積
```

```
loss = F.softmax_cross_entropy(self.W(h), tx)
accum_loss += loss
```

学習

```
# モデルと最適化アルゴリズムの設定
demb = 100
model = MyMT(jv, ev, demb) # モデル生成
optimizer = optimizers.Adam() # 最適化アルゴリズム選択
optimizer.setup(model) # アルゴリズムにモデルをセット

# 学習
for epoch in range(100):
    for i in range(len(jlines)-1):
        jln = jlines[i].split()
        jlnr = jln[::-1]
        eln = elines[i].split()
        model.H.reset_state()
        model.cleargrades()
        loss = model(jlnr, eln) # 誤差の算出
        loss.backward() # 逆方向の計算、勾配の計算
        loss.unchain_backward()
        optimizer.update() # パラメータの更新
    outfile = "mt-" + str(epoch) + ".model"
    serializers.save_npz(outfile, model)
```

日本語の単語列を逆順にしている



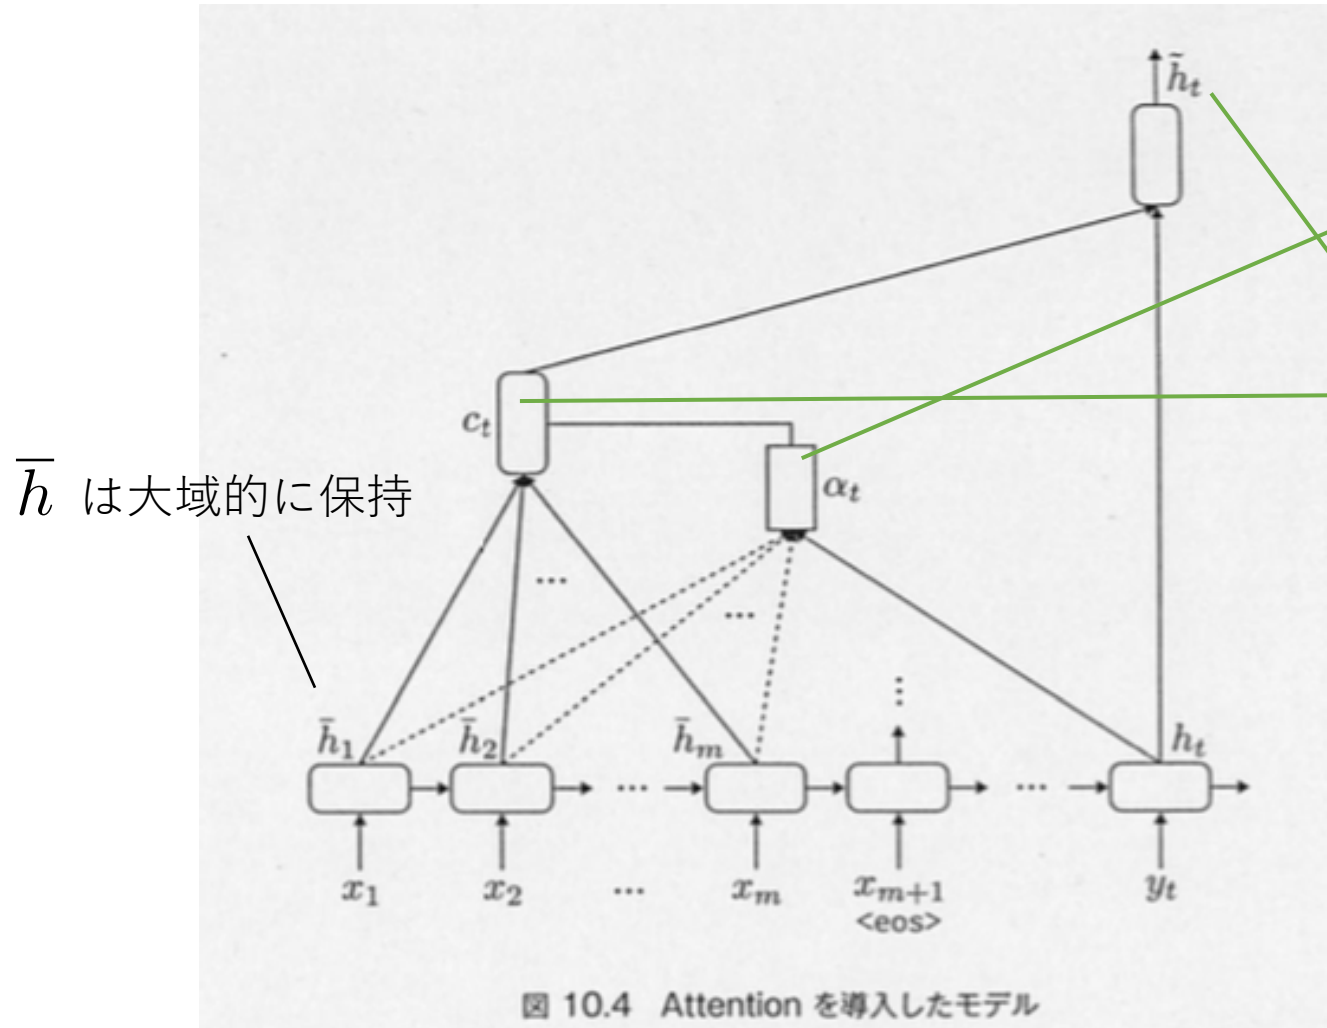
少し結果がよくなる

翻訳

```
def mt(model, jline):
    model.H.reset_state()
    for i in range(len(jline)):
        wid = jvocab[jline[i]]
        x_k = model.embedx(\
            Variable(np.array([wid], dtype=np.int32)))
        h = model.H(x_k)
    x_k = model.embedx(Variable(np.array([jvocab['<eos>']], \
        dtype=np.int32)))

    h = model.H(x_k)
    wid = np.argmax(F.softmax(model.W(h)).data[0])
    print id2wd[wid],
    loop = 0
    while (wid != evocab['<eos>']) and (loop <= 30):
        x_k = model.embedx(Variable(\
            np.array([wid], dtype=np.int32)))
        h = model.H(x_k)
        wid = np.argmax(F.softmax(model.W(h)).data[0])
        print id2wd[wid],
        loop += 1
    print
```

Attentionの導入



$$\alpha_t(i) = \frac{\exp((\bar{h}_i, h_t))}{\sum_{j=1}^m \exp((\bar{h}_j, h_t))}$$



$$c_t = \sum_{i=1}^m \alpha_t(i) \bar{h}_i$$



$$\bar{h}_t = \tanh(W_c [c_t; h_t])$$



Wで重みをつけてsoftmaxを通して出力

Attention導入後のモデル

mk_ct関数

```
demb = 100
def mk_ct(gh, ht):
    s = 0.0
    for i in range(len(gh)):
        s += np.exp(ht.dot(gh[i]))
    ct = np.zeros(demb)
    for i in range(len(gh)):
        alpi = np.exp(ht.dot(gh[i]))/s
        ct += alpi * gh[i]
    ct = Variable(np.array([ct]).astype(np.float32))
    return ct
```

$$\alpha_t(i) = \frac{\exp((\bar{h}_i, h_t))}{\sum_{j=1}^m \exp((\bar{h}_j, h_t))}$$

$$c_t = \sum_{i=1}^m \alpha_t(i) \bar{h}_i$$

Attention導入後のモデル

Encoder

```
# Encoder側
gh = []
self.H.reset_state()
for i in range(len(jline)):
    wid = jvocab[jline[i]]
    x_k = self.embedx(Variable(\
        np.array([wid], dtype=np.int32)))
    h = self.H(x_k)
    # 文脈情報コピー
    gh.append(np.copy(h.data[0]))
x_k = self.embedx(Variable(\
    np.array([jvocab['<eos>']], dtype=np.int32)))
tx = Variable(np.array([evocab[eline[0]], \
    dtype=np.int32]))

h = self.H(x_k)
# Attentionの処理
ct = mk_ct(gh, h.data[0])
h2 = F.tanh(self.Wc1(ct) + self.Wc2(h))
accum_loss = F.softmax_cross_entropy(self.W(h2), tx)
```

$$\tilde{h}_t = \tanh(W_c[c_t; h_t])$$

Attention導入後のモデル

Decoder

```
# Decoder側
for i in range(len(eline[i])):
    wid = evocab[eline[i]]
    x_k = self.embedy(Variable(np.array([wid], \
                                     dtype=np.int32)))

    next_wid = evocab['<eos>'] \
        if (i == len(eline) - 1) \
        else evocab[eline[i+1]]
    tx = Variable(np.array([next_wid], \
                           dtype=np.int32))

    h = self.H(x_k)
    # Attentionの処理
    ct = mk_ct(gh, h.data)
    h2 = F.tanh(self.Wc1(ct) + self.Wc2(h))
    loss = F.softmax_cross_entropy(self.W(h2), tx)
    accum_loss += loss
```

$$\tilde{h}_t = \tanh(W_c[c_t; h_t])$$