

Generative Adversarial Networks, Recurrent Neural Networks, Sequence GANs and Chemoinformatics

Мария Попова

МФТИ, Сколтех, UNC Chapel Hill

6 ноября 2016

Генеративные модели

- Имеется обучающая выборка $x \sim p_{\text{data}}(x)$
- Требуется построить модель для генерации новой выборки: $x \sim p_{\text{model}}(x)$
- При этом $p_{\text{model}} \approx p_{\text{data}}$


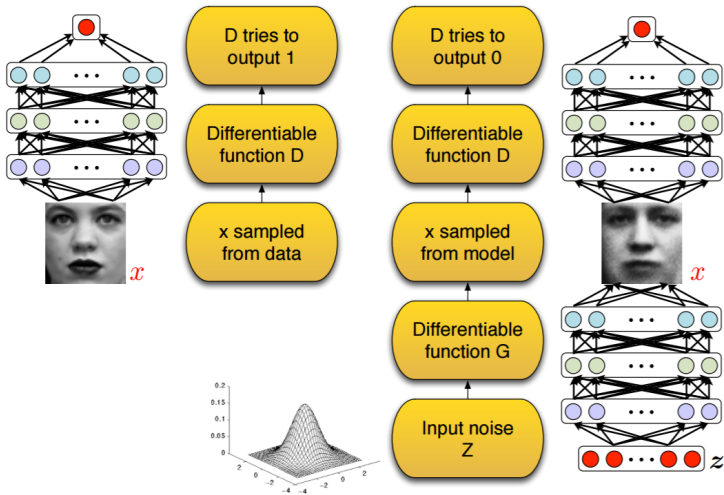


Рис.: $x \sim p_{\text{data}} \rightarrow x \sim p_{\text{model}}$

- Игра между двумя игроками:
 - 1 Генератор G
 - 2 Дискриминатор D
- D учится различать:
 - 1 Данные из обучающей выборки
 - 2 Данные сгенерированные G
- Генератор учится "обманывать" дискриминатор, генерируя данные, которые тяжело отличить от данных из обучающей выборки

GAN framework



$$\min_G \max_D V(D, G) = \mathbb{E}_{\mathbf{x} \sim p_{data}(\mathbf{x})} [\log D(\mathbf{x})] + \mathbb{E}_{\mathbf{z} \sim p_z(\mathbf{z})} [\log(1 - D(G(\mathbf{z})))]$$

Algorithm 1 Minibatch stochastic gradient descent training of generative adversarial nets. The number of steps to apply to the discriminator, k , is a hyperparameter. We used $k = 1$, the least expensive option, in our experiments.

for number of training iterations **do**

for k steps **do**

- Sample minibatch of m noise samples $\{\mathbf{z}^{(1)}, \dots, \mathbf{z}^{(m)}\}$ from noise prior $p_g(\mathbf{z})$.
- Sample minibatch of m examples $\{\mathbf{x}^{(1)}, \dots, \mathbf{x}^{(m)}\}$ from data generating distribution $p_{data}(\mathbf{x})$.
- Update the discriminator by ascending its stochastic gradient:

$$\nabla_{\theta_d} \frac{1}{m} \sum_{i=1}^m \left[\log D(\mathbf{x}^{(i)}) + \log(1 - D(G(\mathbf{z}^{(i)}))) \right].$$


end for

- Sample minibatch of m noise samples $\{\mathbf{z}^{(1)}, \dots, \mathbf{z}^{(m)}\}$ from noise prior $p_g(\mathbf{z})$.
- Update the generator by descending its stochastic gradient:


$$\nabla_{\theta_g} \frac{1}{m} \sum_{i=1}^m \log(1 - D(G(\mathbf{z}^{(i)}))).$$

end for

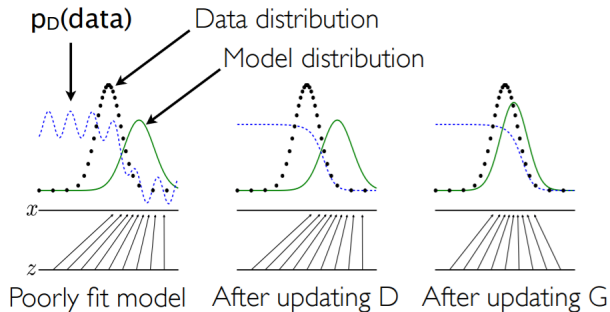
Процесс обучения GAN




Процесс обучения GAN



Процесс обучения GAN



Процесс обучения GAN







MNIST



TFD



CIFAR-10 (fully connected)



CIFAR-10 (convolutional)

$$\mathbf{h}_t = \sigma(\mathbf{x}_t \mathbf{W}_x + \mathbf{h}_{t-1} \mathbf{W}_h + \mathbf{b})$$


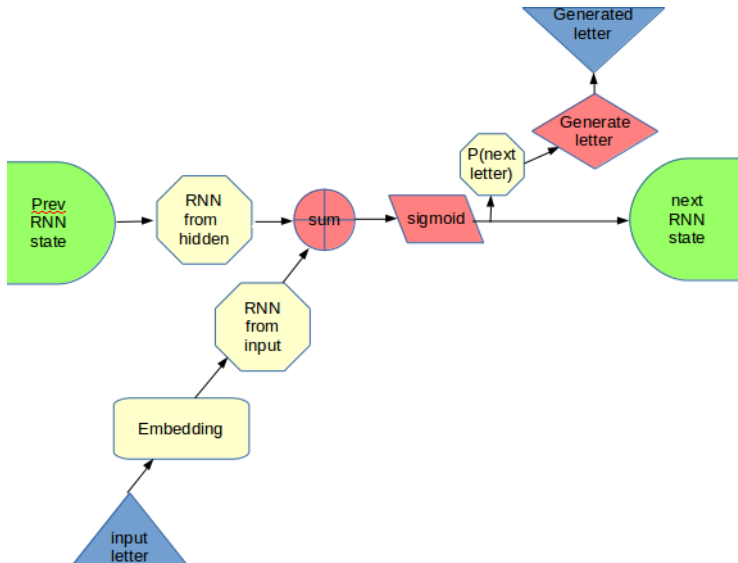



Рис.: Развернутая рекуррентная сеть

Генерация дискретных последовательностей с помощью RNN



Как тренировать RNN и генерировать новые последовательности

- Как тренировать:
 - Метод обратного распространения ошибки
 - Функция ошибки – кросс-энтропия
 - SGD
- Как генерировать:
 - В качестве x_t подаем на вход символ сгенерированный на шаге $t - 1$.



Примеры сгенерированных текстов

Trained on Wikipedia...

The meaning of life is the tradition of the ancient human reproduction: it is less favorable to the good boy for when to remove her bigger. In the show's agreement unanimously resurfaced. The wild pastured with consistent street forests were incorporated by the 15th century BE. In 1996 the primary rapford undergoes an effort that the reserve conditioning, written into Jewish cities, sleepers to incorporate the .St Eurasia that activates the population. Mar??a Nationale, Kelli, Zedlat-Dukastoe, Florendon, Ptu's thought is. To adapt in most parts of North America, the dynamic fairy Dan please believes, the free speech are much related to the

And the Machine Learning Corpus...

Recurrent network with the Stiefel information for logistic regression methods Along with either of the algorithms previously (two or more skewprecision) is more similar to the model with the same average mismatched graph. Though this task is to be studied under the reward transform, such as (c) and (C) from the training set, based on target activities for articles a ? 2(6) and (4.3). The PHDPic (PDB) matrix of cav'va using the three relevant information contains for timing measurements. Moreover, because of the therap tor, the aim is to improve the score to the best patch randomly, but for each initially four data sets. As shown in Figure 11, it is more than 100 steps, we used ?? nto ninfty with 1000

The New World Order

```
: seed = u"Каждый человек должен" #if you are using non-russian text corpora, use seed in it's language instead
sampling_fun = proportional_sample_fun
result_length = 300

generate_sample(sampling_fun,seed,result_length)
```

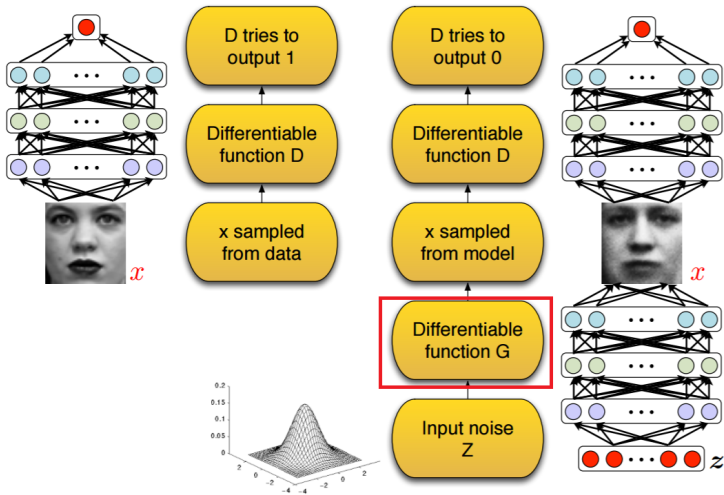
```
----
аждый человек должен, кожета оорисле; коморговленных для судом за постанусти в дицель передания сошей прод
ол временное на недействии рassiипочитель его искается ответствических лиц врему объектерспонениях исполме
няются оснего налостоя исполнение с такой: 1карительному предопределение органами в законо обеспеченную дел
```

```
: seed = u"В случае неповиновения"
sampling_fun = proportional_sample_fun
result_length = 300

generate_sample(sampling_fun,seed,result_length)
```

```
----
случае неповиновения о производстве. Припие, вление приводит в уперетствии членахли лица (портавко эксп
ортных средств, общества, по долоченным редляда аремичей, в обстанты обязан передать комору нерее изъятия б
ез помещении, заместе обеспечен - от проживах без до принятия действию помещений, а также при удовоствранн
```

GAN для генерации дискретных данных



- Проблема:
 - Выход генератора недифференцируем
- Идея: рассматриваем Adversarial процесс с позиции Reinforcement Learning
 - Генератор – RL агент
 - Состояние – текущая сгенерированная последовательность
 - Действие – сгенерировать элемент последовательности
 - Дискриминатор назначает агенту reward

Целевая функция:

$$J(\theta) = \sum_{a_{1:T} \in \mathbb{A}^\dagger} p_\theta(a_{1:T}) R(a_{1:T}) =$$

$$\mathbb{E}_{a_{1:T} \sim p_\theta} \sum_{t=1}^n r(a_{1:t}) =$$

$$\mathbb{E}_{a_1 \sim p_\theta(a_1)} \mathbb{E}_{a_2 \sim p_\theta(a_2|a_1)} \cdots \mathbb{E}_{a_T \sim p_\theta(a_T|a_{1:(T-1)})} \sum_{t=1}^T r(a_{1:t})$$

где \mathbb{A} – это множество всех возможных последовательностей, $a_{1:T}$ – последовательность, $R(a_{1:T})$ – reward за последовательность $a_{1:T}$.

Algorithm 1 Sequence Generative Adversarial Nets


Require: generator policy G_θ ; roll-out policy G_β ; discriminator D_ϕ ; a sequence dataset $\mathcal{S} = \{X_{1:T}\}$

- 1: Initialize G_θ, D_ϕ with random weights θ, ϕ .
- 2: Pre-train G_θ using MLE on \mathcal{S}
- 3: $\beta \leftarrow \theta$
- 4: Generate negative samples using G_θ for training D_ϕ
- 5: Pre-train D_ϕ via minimizing the cross entropy
- 6: **repeat**
- 7: **for** g-steps **do**
- 8: Generate a sequence $Y_{1:T} = (y_1, \dots, y_T) \sim G_\theta$
- 9: **for** t in $1 : T$ **do**
- 10: Compute $Q(a = y_t; s = Y_{1:t-1})$
- 11: **end for**
- 12: Update generator parameters via policy gradient
- 13: **end for**
- 14: **for** d-steps **do**
- 15: Use current G_θ to generate negative examples and combine with given positive examples \mathcal{S}
- 16: Train discriminator D_ϕ for k epochs
- 17: **end for**
- 18: $\beta \leftarrow \theta$
- 19: **until** SeqGAN converges

SMILES strings:

```
1 CCC(C1CCCC1Se1cc(O)c(N)c2C(CC2=C1Nc1cccc1C(CC1cccc1)c1cccc1)N(=O)=O)c1cccc1
2 CC(C)N(C(C)C)c1cc(C)cc(c1)C1=CCCC1
3 CCOC(=O)c1nnc(SCC(=O)NC2COCCNC2c3cccc3-c2nn1-c1cccc1)C2CCCOc1cccc(C)c1O
4 BrC1ccc2nc(-c3ccc(C1)cc3)c[n+](NC(=O)c4ccc(F)cc3)cc2C1=O
5 BrC1ccc2nc(-c3ccc(C1)cc3)c[n+](NC(=O)c4ccc(F)cc3)cc2C1=ONC(=O)c1sccc1C(=O)NC1CC2(OC1(C)C)c1cccc1
6 CCe1cc(ccn1)C1CC(CN1e1cccc1S(=O)(=O)c1cccc1)c1cccc1C
7 ONC(=O)CCc1c(C)c(OC(F)(F)F)cc-c1OCCc1cccc1
8 ONC(=O)CCc1c(C)c(OC(F)(F)F)cc-c1OCCc1cccc1CN(Ce1cccc1)C(CCc1cccc1F)C(=O)OC
9 COe1ccc2C3CN(C(C)CC3)C(=O)Cc12
10 CC(C)(CO)Nc1nc(C)c(nc1-c1ccc(cc1)S(F)(F)-c1ccc(C1)cc1)C(F)(F)F
11 O=C1Nc2sccc2-c2[nH]cc2c1C1
12 O=C1Nc2sccc2-c2[nH]cc2c1C1NC1CCc2ccc(NC(=O)Nc3ccc(NC(=O)c4nc(NCCCN4CCCC5)cc5)cc4)ccc2C(F)(F)F3
13 FC(F)(N1CCOCC1)c1nc2ccc(Nc3nc4cccc4[nH]3)ccn21
14 FC(F)(N1CCOCC1)c1nc2ccc(Nc3nc4cccc4[nH]3)ccn21CN(C)c1ccc(cc1)C(=O)NCc1ncs1
15 COe1ccc2nc(ccc2n1)N1CC(CO)C(O)C1O
16 COe1ccc2nc(ccc2n1)N1CC(CO)C(O)C1OCCOe1ccc(c(F)c1)-c1cc2CCN(C)c2c(C)c1C#N
17 Cc1cccc(C)c1CNS(=O)(=O)c1ccc(OC2CC3CCCC23)cc1
18 Cc1cccc(C)c1CNS(=O)(=O)c1ccc(OC2CC3CCCC23)cc1CNc1cccc1CNc1ccc2c(N)nn2c2c1C#Cc1ccc(C1)cc1
19 CC(C)Nc1ncc(nn1)-c1c(oc2ccc(O)cc12)-c1cnc(nn1)-c1cccc1
20 CC(C)Nc1ncc(nn1)-c1c(oc2ccc(O)cc12)-c1cnc(nn1)-c1cccc1CC(=NNC(=O)c1cccc1)c1ccc2[nH]nc(C)c2c1
21 OCC1=CN(C2CC2)C(C1)C1CCC2C01
22 OCC1=CN(C2CC2)C(C1)C1CCC2C01CN(C)CCOc1c(C(=O)N2CCCC2)c(CO)n1CCC0
23 CC1=CC(OC(C)=O)OC2C=C(C=C(C)C12)#Cc1c(C)cc(C)cc1C
```

Приложения в хемоинформатике



- Ian J. Goodfellow et al. Generative Adversarial Networks arXiv:1406.2661
- Ian J. Goodfellow et al.
<http://www.cs.toronto.edu/~dtarlow/pos14/talks/goodfellow.pdf>
- Ilya Sutskever et al.
<https://prezi.com/ch-dlduspqif/generating-text-with-rnns/>
- Lantao Yu et al. SeqGAN: Sequence Generative Adversarial Nets with Policy Gradient arXiv:1609.05473
- Wojciech Zaremba et al. Reinforcement Learning Neural Turing Machines arXiv:1505.00521