Машинное обучение (Machine Learning)

Глубокие порождающие модели: вариационный автокодер, соперничающие сети (Deep Generative Learning: VAE, GAN)

Уткин Л.В.

Санкт-Петербургский политехнический университет Петра Великого

Содержание

Презентация является компиляцией и заимствованием материалов из замечательных презентаций и материалов по машинному обучению:

Oliver Duerr, Carl Doersch, Bohyung Han, Eric Jang

Порождающие модели

Мотивация

https://www.youtube.com/watch?v=XNZIN7Jh3Sg

Мотивация

http://www.dpkingma.com/sgvb_mnist_demo/demo.html

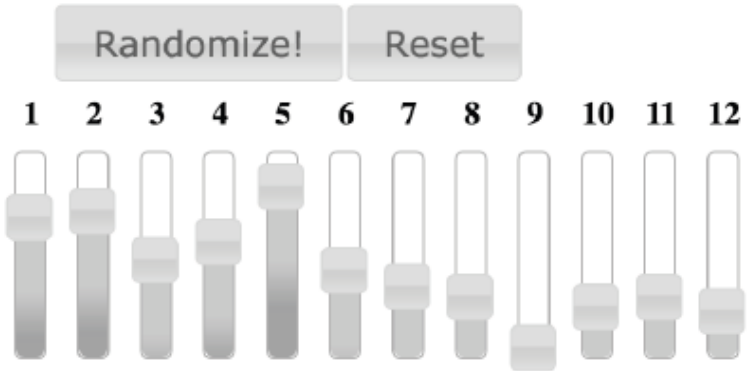

скрытые z

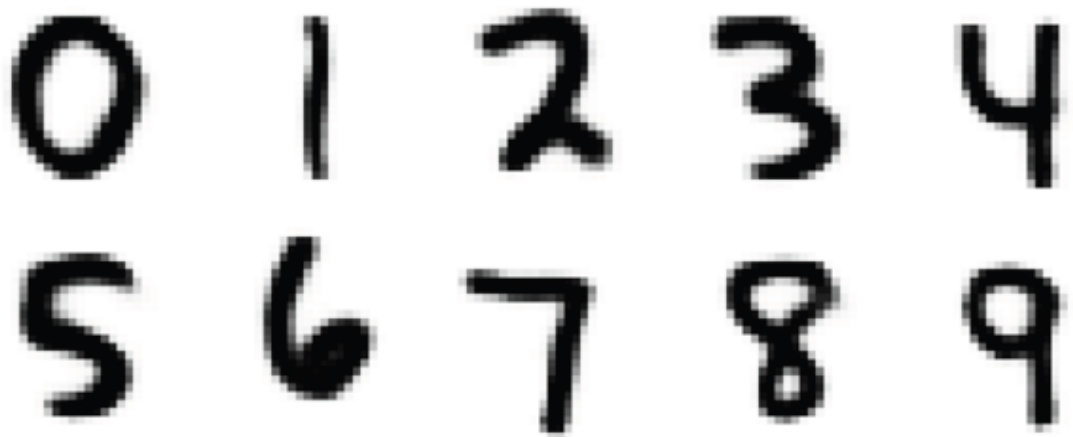

наблюдаемые x

Порождающие и разделяющие модели

1. **Разделяющие модели (дискриптивные)**: Оценка параметров на основе максимизации правдоподобия обучающей выборки по отношению к вероятности класса, а затем классификатор относит объект к его наиболее вероятному классу.
2. **Порождающие модели**: максимизация правдоподобия совместного распределения объектов и классов, а затем использование формулы Байеса для нахождения вероятности отношения объекта к классу.

Порождающие и разделяющие модели

- Пусть $(\mathbf{x}, y)$ - входные данные
- Результат обучения порождающей модели - совместное распределение вероятностей $p(\mathbf{x}, y)$
- Результат обучения разделяющей модели - условное распределение $p(y|\mathbf{x})$.
- Рассмотрим 4 точки данных:
  $(\mathbf{x}, y) \rightarrow \{(0,0),(0,0),(1,0),(1,1)\}$

$p(\mathbf{x}, y)$		
	$y=0$	$y=1$
$x=0$	$1/2$	0
$x=1$	$1/4$	$1/4$

$p(\mathbf{x}\|y)$		
	$y=0$	$y=1$
$x=0$	1	0
$x=1$	$1/2$	$1/2$

Порождающие модели

Порождающая модель позволяет оценить совместное распределение вероятностей $p(\mathbf{x}, y)$. Это означает, что можно сгенерировать $\mathbf{x}, y$ в соответствии с $p(\mathbf{x}, y)$.

Порождающие и разделяющие модели

1. **Разделяющий** алгоритм пытается найти $p(y|\mathbf{x})$ из данных и затем классифицировать их или пытается найти разделяющую функцию между классами.
   Порождающий алгоритм пытается найти $p(\mathbf{x}, y)$, которое затем трансформируется в $p(y|\mathbf{x})$.
2. **Порождающий** алгоритм может использовать $p(\mathbf{x}, y)$, чтобы генерировать новые даные, аналогичные уже существующим.
   Разделяющий алгоритм в общем имеет лучше характеристики в задачах классификации.
3. **Порождающий**: Наивный Байес
   Разделяющий: Логистич. регрессия, SVM, Нейронные сети

Порождающие модели на основе нейронных сетей

1. **Вариационный автокодер (Variational AutoEncoder (VAE))**
2. Порождающие конкурирующие сети (Generative Adversarial Networks (GANs))
3. Глубокая машина Больцмана (DBM)
4. Глубокая сеть доверия (DBN)

Вспомним регрессию

Часть людей представляют регрессию как множество точек и аппроксимирующую прямую

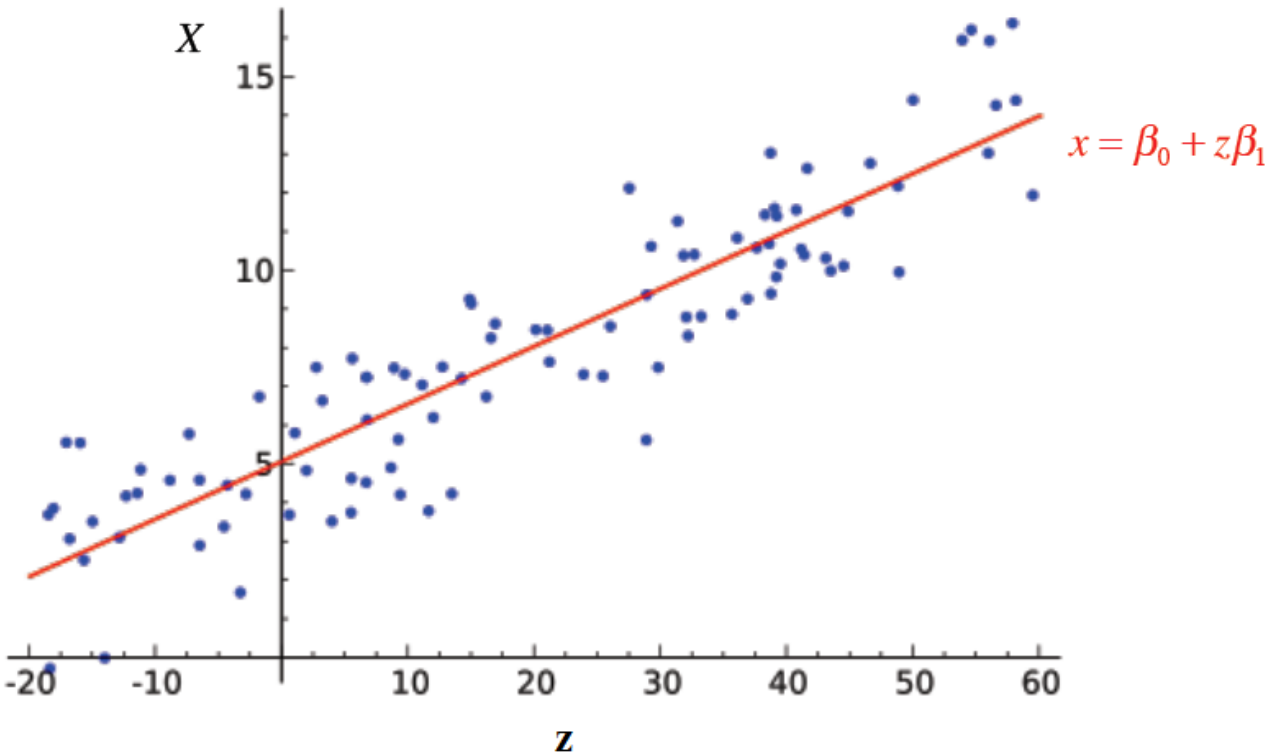

Вспомним регрессию еще

Статистики добавляют $P_\theta(X|Z)$: плюсы добавления модели ошибок:

- Какова вероятность точки данных
- Доверительные границы
- Сравниваемость моделей

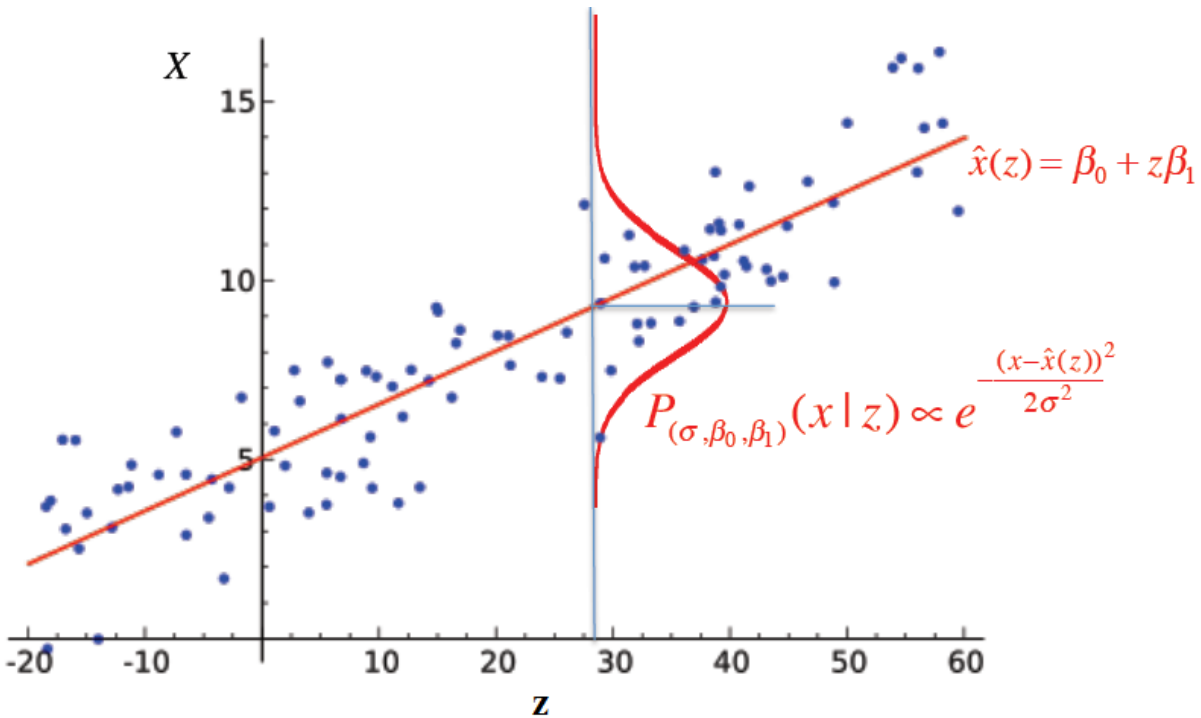

Вспомним регрессию с графическими моделями

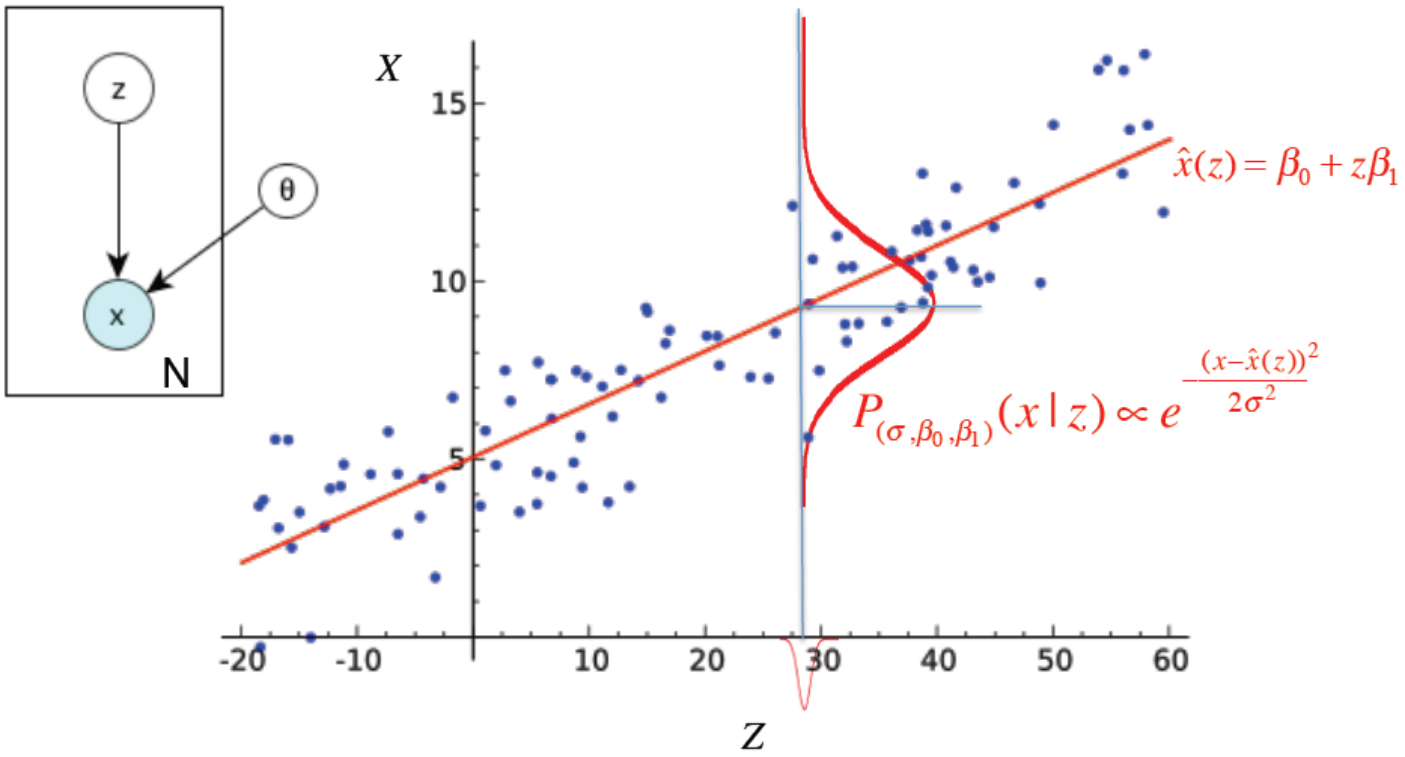

Переход от малой размерности к большой

Переход от $\mathbb{R}^1$ к $\mathbb{R}^{10000}$

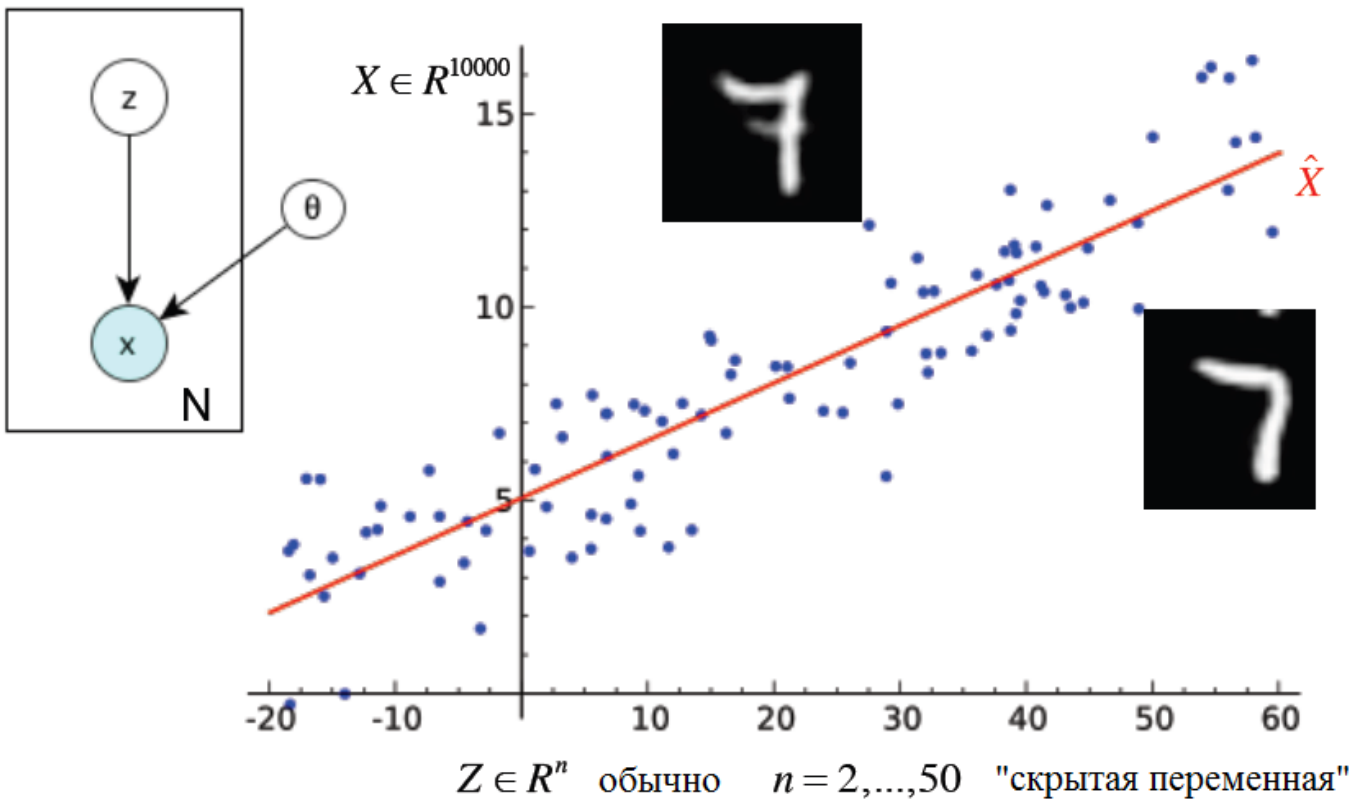

Скрытые переменные

- Рассмотрим задачу генерации изображений цифр от 0 до 9.
- Если левая половина цифры - левая половина 5, то правая половина не может быть левой половиной 0. Это помогает принимать решение какую цифру генерировать.
- Такое решение отражается в скрытой переменной z (latent variable).
- Перед тем, как модель нарисует что-нибудь, она сначала сгенерирует число z из $\{0, \ldots, 9\}$, затем убеждается, все ли штрихи совпадают с этой цифрой.
- z называется “скрытой”, так как при данной цифре, порожденной моделью, мы не знаем точно, какие параметры z сгенерировали цифру.

Скрытые переменные

Неформально: Чтобы говорить о качестве модели, необходимо удостовериться, что для каждой точки $\mathbf{x}$ в обучающей выборке S, есть "окружение" скрытой переменной, которое заставляет модель генерировать что-то очень похожее на $\mathbf{x}$.

Формально:

- Дано: вектор скрытых переменных $\mathbf{z} \sim p(\mathbf{z})$; семейство функций $f(\mathbf{z}; \theta)$, θ - вектор параметров
- Нужно оптимизировать θ так, что $f(\mathbf{z}; \theta)$ производит выборку подобно $\mathbf{x}$ с высокой вероятностью для каждого $\mathbf{x} \in S$, когда $\mathbf{z}$ генерируется из $p(\mathbf{z})$

Некоторое отступление

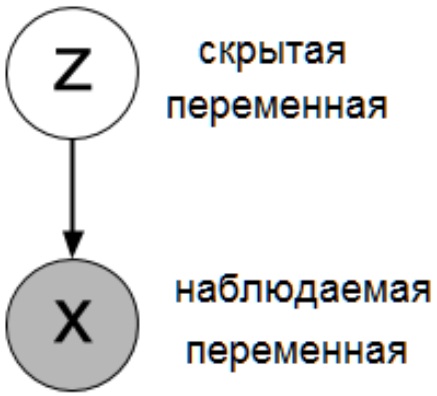

Пусть **x** представляет “исходные значения пикселей изображения”, а z - двоичная переменная такая, что $z = 1$, если “**x** - изображение кота”.

Некоторое отступление

$X=$ 

$P(z)=1$ (точно кот)

$X=$ 

$P(z)=0$ (точно не кот)

$X=$ 

$P(z)=0.1$ (напоминает кота)

Некоторое отступление

- Теорема Байеса устанавливает связь между переменными:

$$p(\mathbf{z}|\mathbf{x}) = \frac{p(\mathbf{x}|\mathbf{z})p(\mathbf{z})}{p(\mathbf{x})}$$

- $p(\mathbf{z}|\mathbf{x})$ - постериорная вероятность: “дано изображение, какова вероятность, что это кот?” Если можно сгенерировать $\mathbf{z} \sim p(\mathbf{z}|\mathbf{x})$, то значения можно использовать для построения классификатора, который скажет, является ли данное изображение котом или нет.

Некоторое отступление

- $p(\mathbf{x}|\mathbf{z})$ - правдоподобие: “дано значение $\mathbf{z}$, как вероятно, что изображение $\mathbf{x}$ определенной категории { кот / не кот} ”. Если можно сгенерировать $\mathbf{x} \sim p(\mathbf{x}|\mathbf{z})$, то можно сгенерировать изображения котов и изображения не котов также просто, как генерацию случайных чисел.
- $p(\mathbf{z})$ - априорная веротяность (любая информация о $\mathbf{z}$), например, если известно, что $1/3$ всех изображений - коты, то $p(\mathbf{z} = 1) = 1/3$ и $p(\mathbf{z} = 0) = 2/3$.

А это важно - здесь суть подхода

Скрытые переменные можно интерпретировать в рамках байесовского подхода как априорные доверия, связанные с наблюдаемыми переменными.

Например, если мы полагаем, что $\mathbf{x}$ *имеет многомерное нормальное распределение, то скрытая переменная* $\mathbf{z}$ *может представлять среднее и дисперсию нормального распределения. Распределение* $p(\mathbf{z})$*, определенное на параметрах, является априорным для* $p(\mathbf{x})$*.*

Генерируя $\mathbf{z}$ *(различные параметры), мы можем генерировать различные* $\mathbf{x}$*!*

В чем проблема?

- Для сложных задач мы не знаем, как генерировать из $p(\mathbf{z}|\mathbf{x})$ или как вычислить $p(\mathbf{x}|\mathbf{z})$.
- Мы знаем форму $p(\mathbf{z}|\mathbf{x})$, но соответствующее вычисление настолько является сложным, что мы не можем оценить его за приемлемое время.
- Можно попытаться использовать какой-нибудь известный подход для этого, но большинство из них медленно сходится.

Идея вариационного вывода

Вместо сложного распределения $p(\mathbf{z}|\mathbf{x})$, используем простое параметрическое распределение $q_\phi(\mathbf{z}|\mathbf{x})$, например, нормальное, для которого известно, как получить апостериорное распределение. При этом мы подбираем параметры ϕ таким образом, чтобы q_ϕ было как можно ближе к $p(\mathbf{z}|\mathbf{x})$.

Близость определяется, например, при помощи дивергенции Кульбака-Лейблера.

Иллюстрация близких распределений

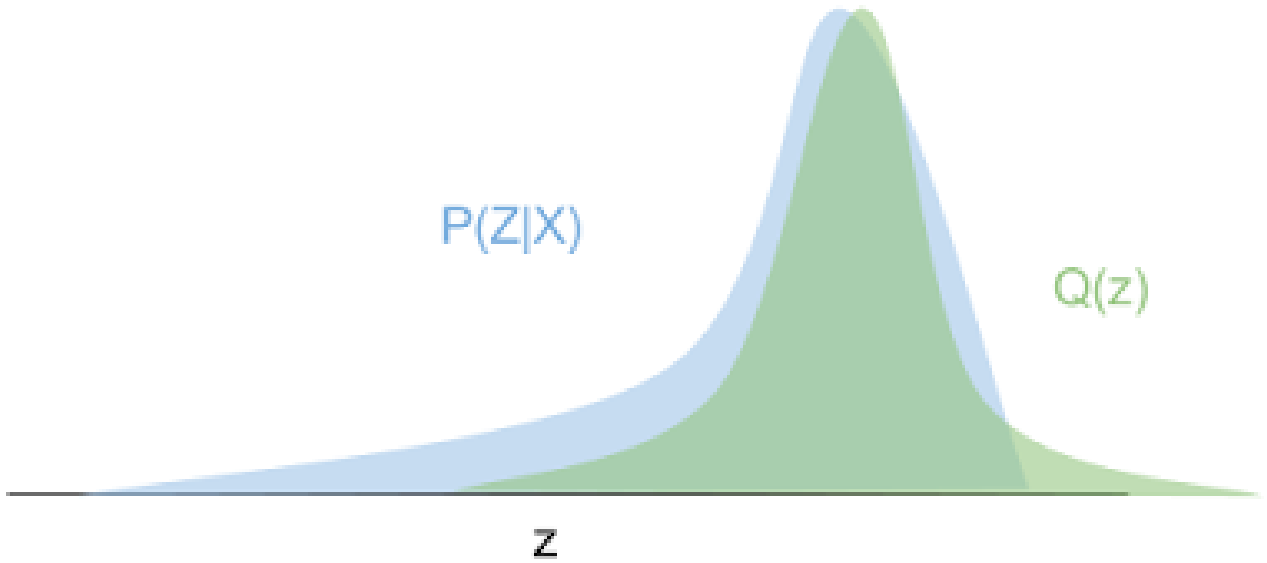

Совсем формально

$$p(\mathbf{x}) = \int p(\mathbf{x}|\mathbf{z};\theta)p(\mathbf{z})d\mathbf{z} = \mathbb{E}_{\mathbf{z}\sim p(\mathbf{z})}p(\mathbf{x}|\mathbf{z};\theta) \to \max_{\theta}$$

- $f(\mathbf{z};\theta)$ заменена распределением $p(\mathbf{x}|\mathbf{z};\theta)$
- Если модель способна воспроизвести обучающие примеры, то она также способна с большой вероятностью породить аналогичные и с малой вероятностью неподобные примеры.

Забегая вперед

- В вариационном автокодере, если $\mathbf{x} \in \mathbb{R}$, то $p(\mathbf{x}|\mathbf{z};\theta) = \mathcal{N}(\mathbf{x}|f(\mathbf{z};\theta), \sigma^2 \cdot I)$ - нормальное распределение со средним $f(\mathbf{z};\theta)$ и дисперсией $\sigma^2 \cdot I$
- Тогда можно увеличивать постепенно $p(\mathbf{x}|\mathbf{z};\theta)$ делая $f(\mathbf{z};\theta)$ близким к $\mathbf{x}$ для некоторого $\mathbf{z}$
- Если $\mathbf{x}$ - двоичное, то then $p(\mathbf{x}|\mathbf{z};\theta)$ - распределение Бернулли с параметром $f(\mathbf{z};\theta)$

Забегая еще далее

Для решения задачи с $p(\mathbf{x})$ имеются 2 проблемы:

1. как определить скрытые переменные $\mathbf{z}$, т.е. решить, какую информацию они представляют?
2. что делать с интегрированием по $\mathbf{z}$?

Вариационный автокодер позволяет ответить на эти вопросы

Как определить скрытые переменные

Мы хотим в идеале избежать:

- принятия решения “в ручную”, какую информацию каждая координата вектора $\mathbf{z}$ кодирует
- в явном виде описывать зависимости (скрытую структуру) между координатами $\mathbf{z}$

Вариационный автокодер (VAE)

Подход VAE

- Подход VAE для решения: он предполагает, что нет простой интерпретации координат $\mathbf{z}$, и вместо это предлагает, что выборку $\mathbf{z}$ можно сгенерировать из простого распределения, например, из $\mathcal{N}(0, I)$!
- Ключевая идея: любое распределение размерности d может быть сгенерировано, взяв множество d нормально распределенных переменных и отобразить их, используя достаточно сложную функцию

Подход VAE

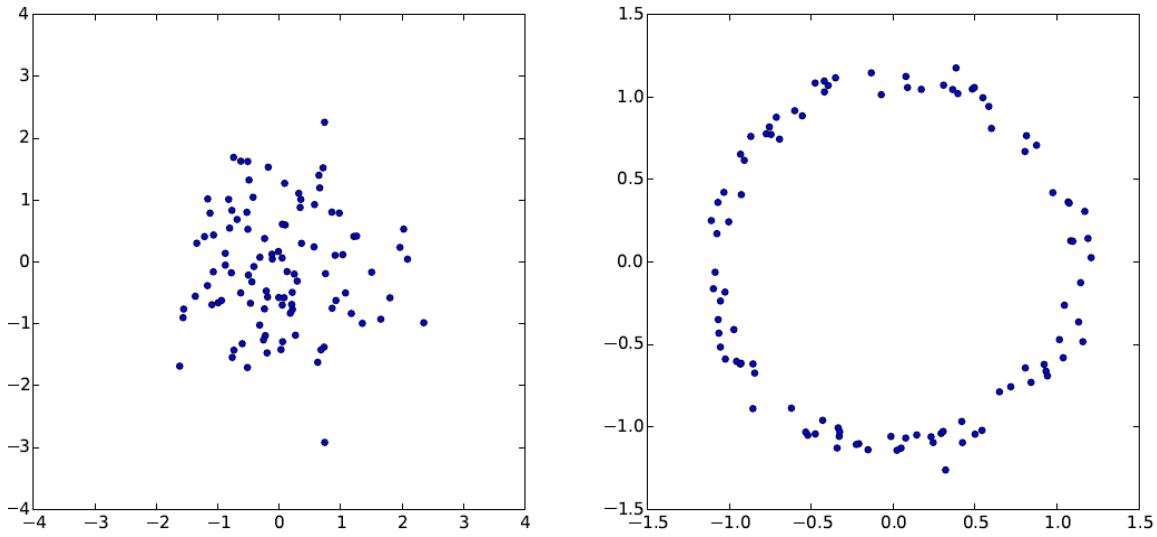

- Слева: выборка z из нормального распределения
- Справа: та же выборка, но с $g(z) = z/10 + z/\|\mathbf{z}\|$ образует кольцо
- Детерминированная функция g “обучается” из данных

Стандартный автокодер для представления признаков

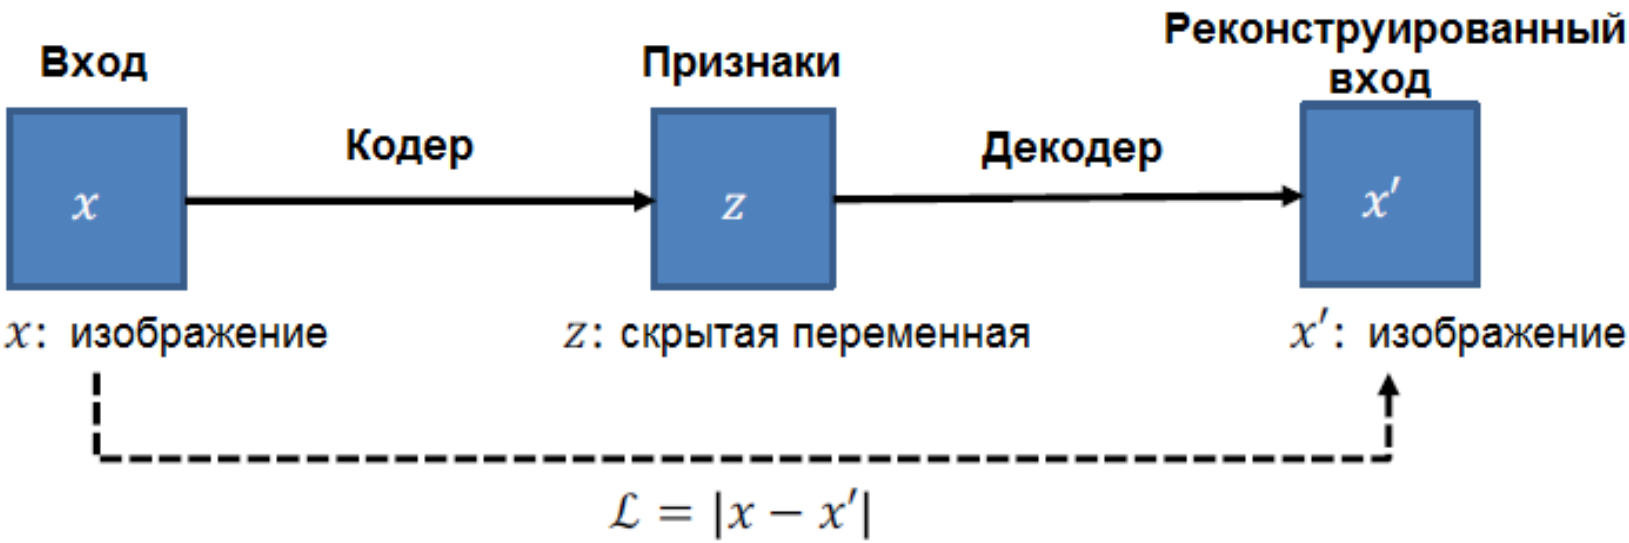

Стандартный автокодер для классификации

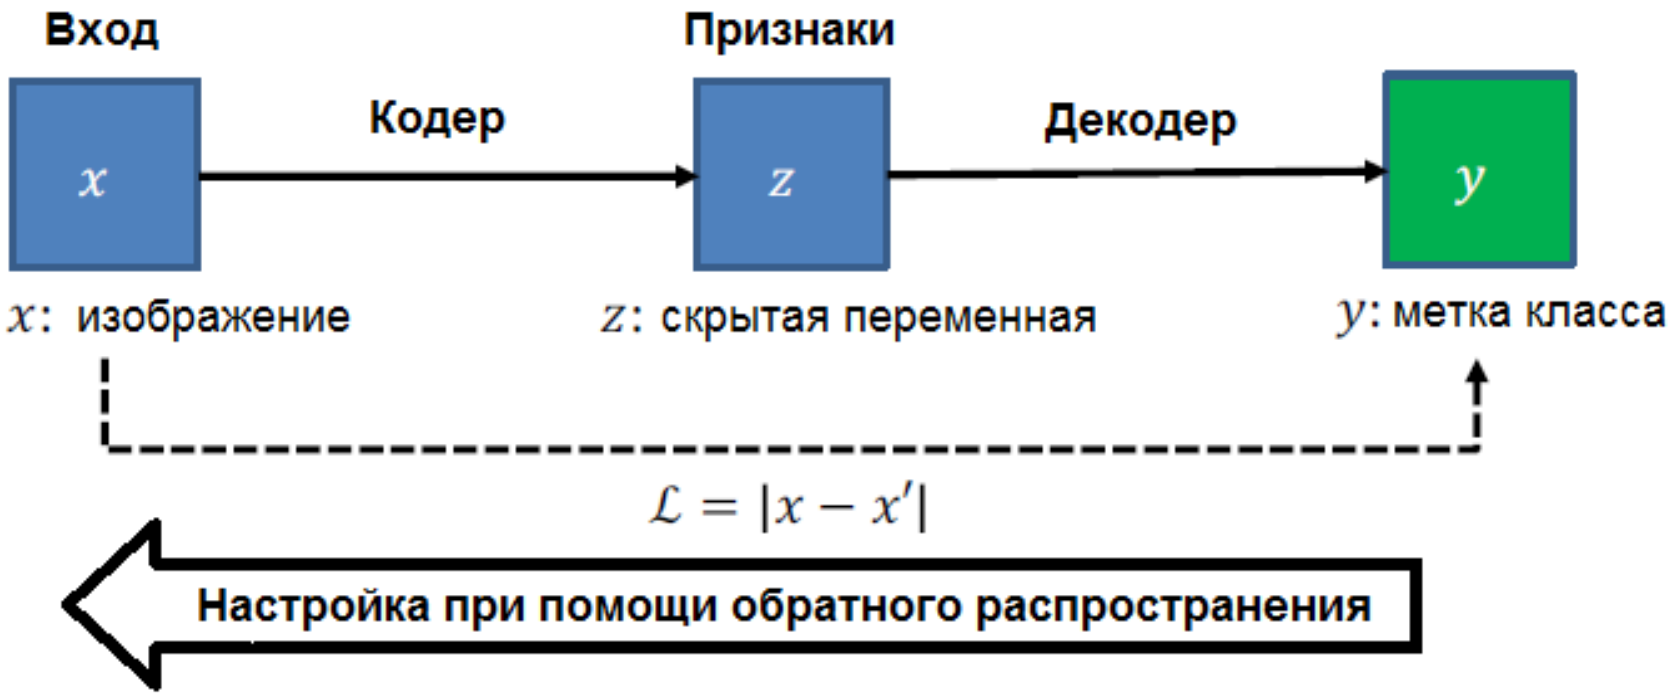

Вариационный автокодер

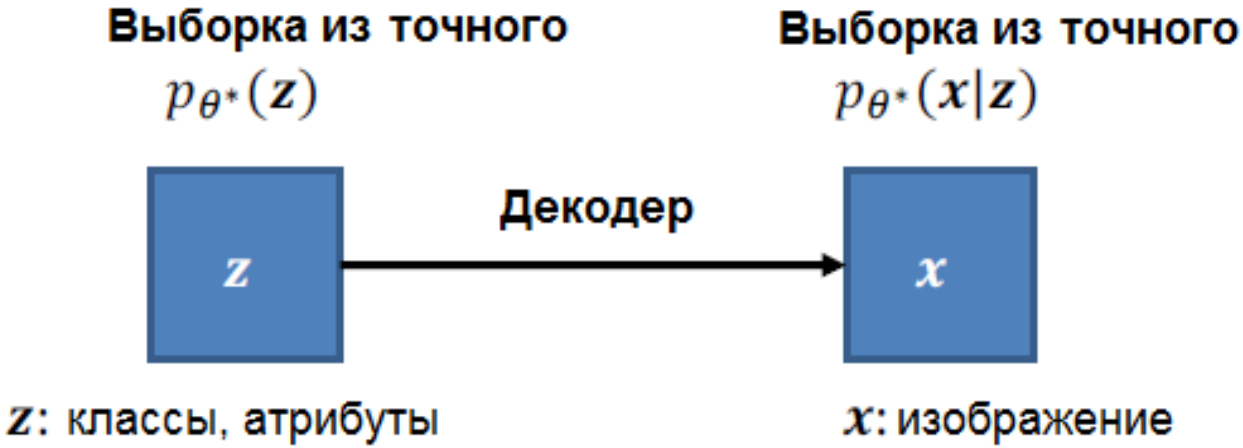

- Значение генерируется из априорного распределения $p_{\theta*}(\mathbf{z})$
- Значение $\mathbf{x}^{(i)}$ генерируется из условного распределения $p_{\theta*}(\mathbf{x}|\mathbf{z})$
- Точное значение параметра θ^* и значения скрытых переменных $\mathbf{z}^{(i)}$ не известны

Вариационный автокодер (кодирование)

Дано: $\mathbf{z} \sim \mathcal{N}(0, I)$, $\mathbf{x}|\mathbf{z} \sim p_{\theta*}(\mathbf{x}|\mathbf{z})$

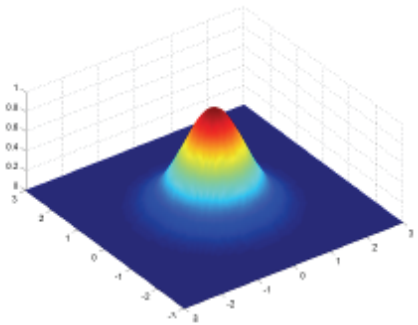

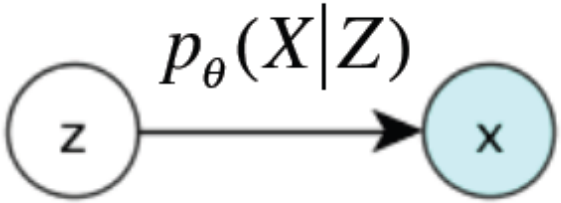

Один пример

Хотим получить (обучиться) θ из N обучающих наблюдений $\mathbf{x}^{(i)}$, $i = 1, ..., N$

Вариационный автокодер

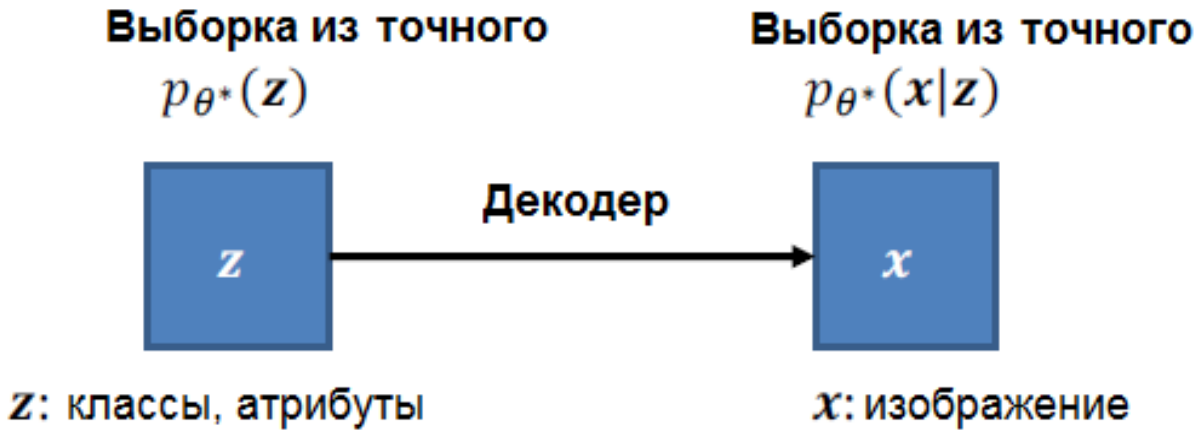

- Трудно оценить $p_{\theta^*}(\mathbf{z})$ и $p_{\theta^*}(\mathbf{x}|\mathbf{z})$ на практике
- Необходимо аппроксимировать эти распределения

Вариационный автокодер - основная идея

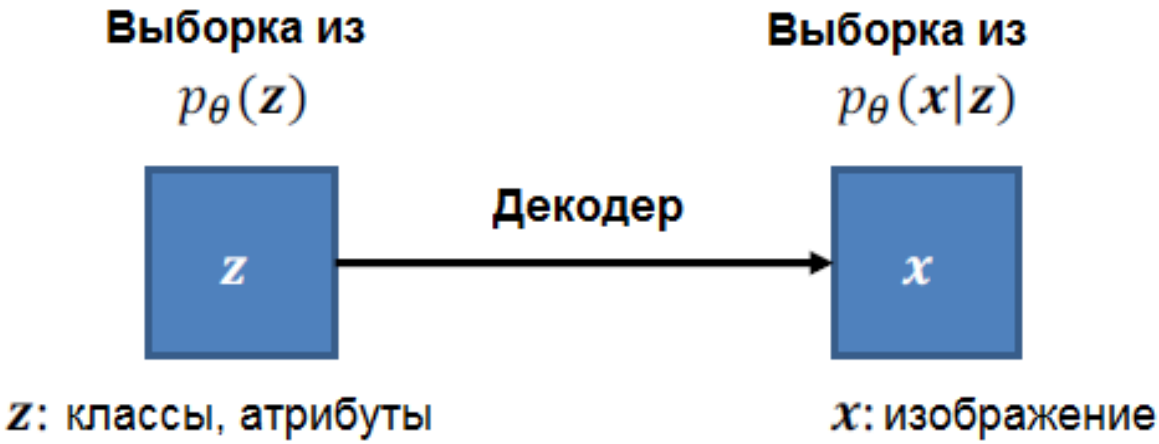

- Предполагаем, что $p_\theta(\mathbf{z})$ имеет нормальное распределение
- Предполагаем, что $p_\theta(\mathbf{x}|\mathbf{z})$ имеет диагональное нормальное распределение
- Декодер оценивает среднее и дисперсию $p_\theta(\mathbf{x}|\mathbf{z})$

Декодирование

Пусть $z \in \mathbb{R}$ и $x \in \mathbb{R}^2$

Идея: Нейр.сеть + Норм. распр (или Бернулли) с диагональной ковариацией Σ

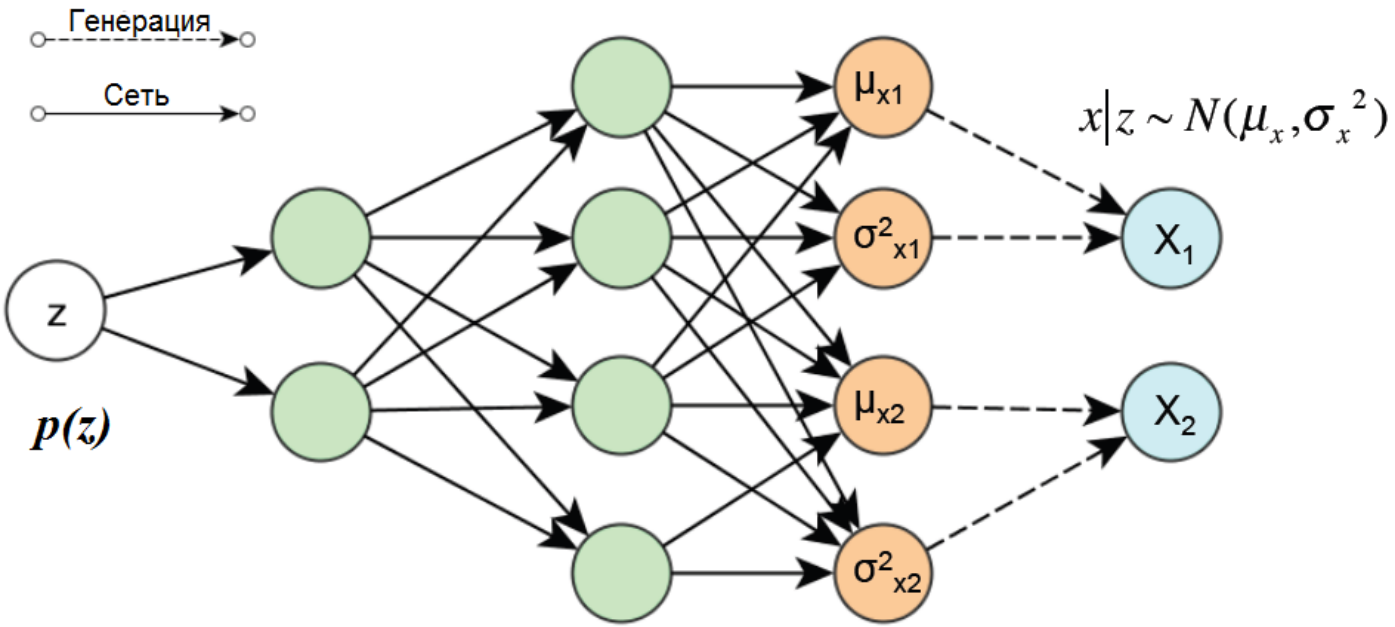

Вариационный автокодер - основная идея

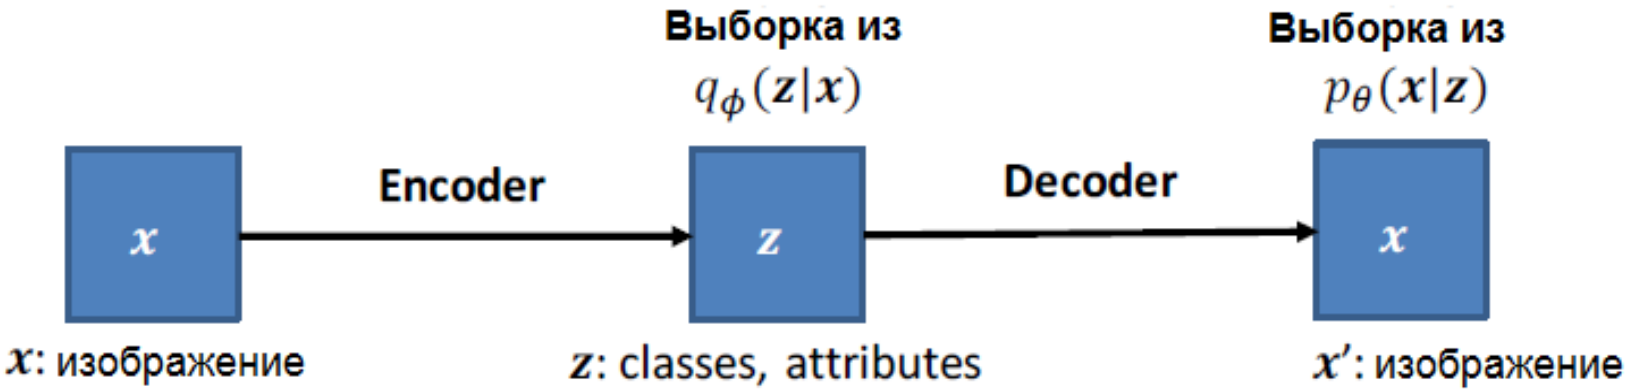

- Кодер оценивает среднее и дисперсию $q_\phi(\mathbf{x}|\mathbf{z})$
- Декодер оценивает среднее и дисперсию $p_\theta(\mathbf{x}|\mathbf{z})$
- Максимизируем нижнюю границу маргинального правдоподобия $p_\theta(\mathbf{x}|\mathbf{z})$

Декодирование

NN прямого распространения + Gaussian:
$q_\phi(\mathbf{x}|\mathbf{z}) = \mathcal{N}(\mathbf{z}; \mu_\mathbf{z}(\mathbf{x}), \sigma_\mathbf{z}(\mathbf{x}))$

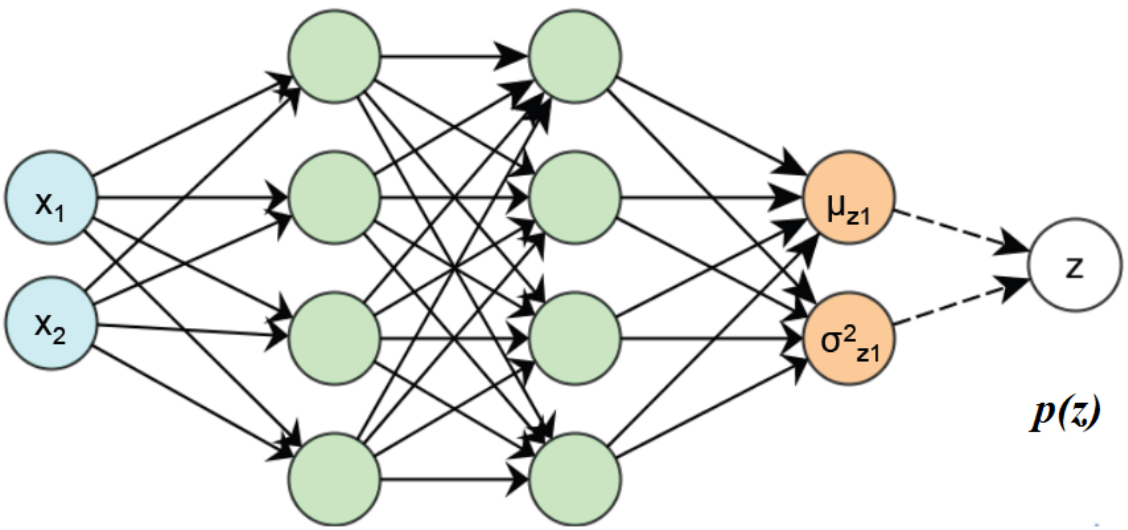

Таким образом

Если генерация $\mathbf{z} \sim q(\mathbf{z}|\mathbf{x})$ является “кодированием”, которое конвертирует наблюдение $\mathbf{x}$ в скрытый код $\mathbf{z}$, то генерация $\mathbf{x} \sim q(\mathbf{x}|\mathbf{z})$ - “декодирование”, которое реконструирует наблюдения из $\mathbf{z}$.

Весь автокодер

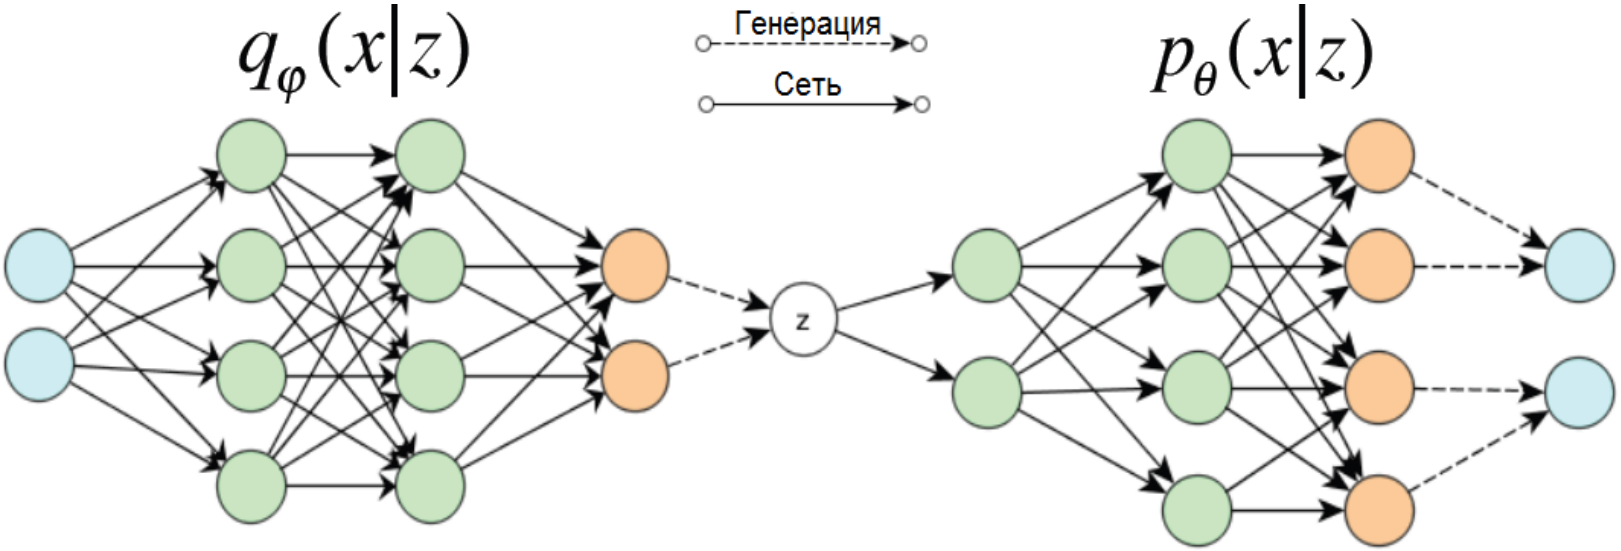

- Параметры φ и θ обучаются при помощи обратного распространения
- Главное определить функцию потерь

Выбор функции потерь

- Какая техника в статистике является одной из лучших?
- Метод максимального правдоподобия: настройка φ и θ, чтобы максимизировать функцию правдоподобия
- Максимизируем логарифм правдоподобия для заданного "изображения" $\mathbf{x}^{(i)}$ обучающего множества
- Суммируем по всем обучающим примерам

Нижняя граница функции правдоподобия

$$L = \log p(\mathbf{x}) = \sum_{\mathbf{z}} q(\mathbf{x}|\mathbf{z}) \log p(\mathbf{x}) = \sum_{\mathbf{z}} q(\mathbf{x}|\mathbf{z}) \log \left(\frac{p(\mathbf{z}, \mathbf{x})}{p(\mathbf{z}|\mathbf{x})} \right) =$$

$$= \sum_{\mathbf{z}} q(\mathbf{x}|\mathbf{z}) \log \left(\frac{p(\mathbf{z}, \mathbf{x})}{q(\mathbf{z}|\mathbf{x})} \frac{q(\mathbf{z}|\mathbf{x})}{p(\mathbf{z}|\mathbf{x})} \right) =$$

$$= \sum_{\mathbf{z}} q(\mathbf{x}|\mathbf{z}) \log \left(\frac{p(\mathbf{z}, \mathbf{x})}{q(\mathbf{z}|\mathbf{x})} \right) + \sum_{\mathbf{z}} q(\mathbf{x}|\mathbf{z}) \log \left(\frac{q(\mathbf{z}|\mathbf{x})}{p(\mathbf{z}|\mathbf{x})} \right) =$$

$$= L^v + KL(q(\mathbf{z}|\mathbf{x})||p(\mathbf{z}|\mathbf{x})) \geq L^v$$

- KL определяет, насколько $q(\mathbf{z}|\mathbf{x})$ близко к $p(\mathbf{z}|\mathbf{x})$
- L^v - нижняя граница для правдоподобия; $L^v = L$ при $q(\mathbf{z}|\mathbf{x}) = p(\mathbf{z}|\mathbf{x})$

Приближенный вывод

$$
\begin{aligned}
L^v &= \sum_{\mathbf{z}} q(\mathbf{x}|\mathbf{z}) \log \left(\frac{p(\mathbf{z}, \mathbf{x})}{q(\mathbf{z}|\mathbf{x})} \right) = \\
&= \sum_{\mathbf{z}} q(\mathbf{x}|\mathbf{z}) \log \left(\frac{p(\mathbf{x}|\mathbf{z}) \cdot p(\mathbf{z})}{q(\mathbf{z}|\mathbf{x})} \right) = \\
&= \sum_{\mathbf{z}} q(\mathbf{x}|\mathbf{z}) \log \left(\frac{p(\mathbf{z})}{q(\mathbf{z}|\mathbf{x})} \right) + \sum_{\mathbf{z}} q(\mathbf{x}|\mathbf{z}) \log \left(p(\mathbf{x}|\mathbf{z}) \right) = \\
&= -KL(q(\mathbf{z}|\mathbf{x}^{(i)})||p(\mathbf{z})) + \mathbb{E}_{q(\mathbf{z}|\mathbf{x}^{(i)})} \left[p(\mathbf{x}^{(i)}|\mathbf{z}) \right]
\end{aligned}
$$

Приближенный вывод

$$L^v = -KL(q(\mathbf{z}|\mathbf{x}^{(i)})||p(\mathbf{z})) + \mathbb{E}_{q(\mathbf{z}|\mathbf{x}^{(i)})}\left[p(\mathbf{x}^{(i)}|\mathbf{z})\right]$$

- $-KL(q(\mathbf{z}|\mathbf{x}^{(i)})||p(\mathbf{z}))$ - **регуляризация** $p(\mathbf{z})$ - обычно $\mathcal{N}(\mathbf{z}; 0, 1)$
- $\mathbb{E}_{q(\mathbf{z}|\mathbf{x}^{(i)})}\left[\log p(\mathbf{x}^{(i)}|\mathbf{z})\right]$ - **качество реконструкции**, $\log(1)$, если $\mathbf{x}^{(i)}$ реконструируется идеально ($\mathbf{z}$ образует $\mathbf{x}^{(i)}$)

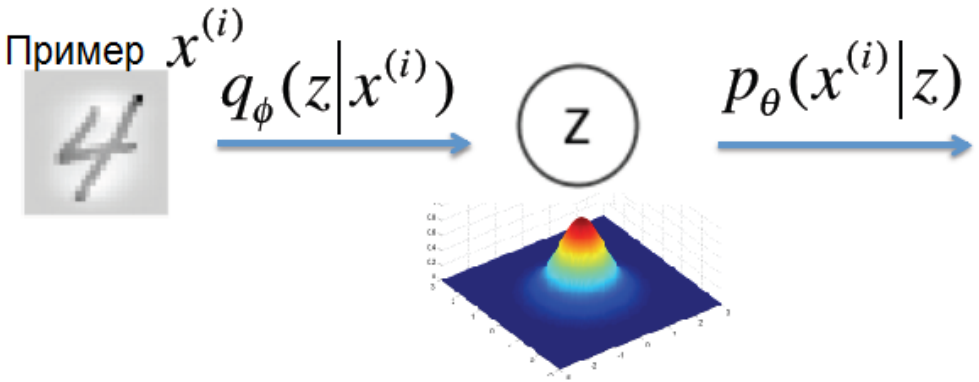

Вычисление регуляризациии

- Используем $\mathcal{N}(\mathbf{z}; 0, 1)$ как априорное для $p(\mathbf{z})$
- $q(\mathbf{z}|\mathbf{x}^{(i)})$ - норм. с параметрами $\mu_{\mathbf{z}}^{(i)}, \sigma_{\mathbf{z}}^{(i)}$, определяемыми NN

$$-KL(q(\mathbf{z}|\mathbf{x}^{(i)})||p(\mathbf{z})) = \frac{1}{2}\sum_{j=1}^{J}\left(1 + \log\left(\sigma_{\mathbf{z}_j}^{(i)2}\right) - \mu_{\mathbf{z}_j}^{(i)2} - \sigma_{\mathbf{z}_j}^{(i)2}\right)$$

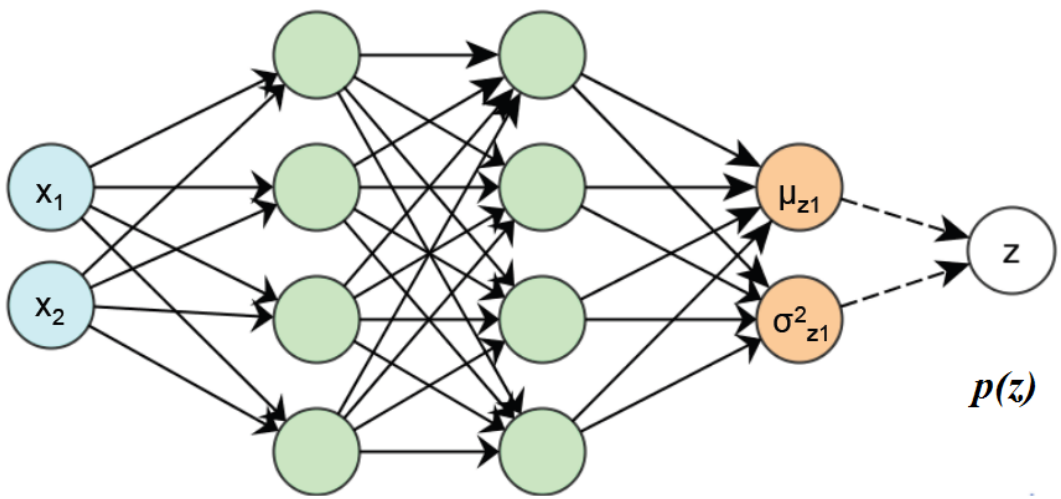

Вычисление качества реконструкции

Приближенное вычисление $\mathbb{E}_{q(\mathbf{z}|\mathbf{x}^{(i)})}$ генерацией $\mathbf{z}^{(i,l)} \sim q(\mathbf{z}|\mathbf{x}^{(i)})$, $l = 1, ..., M$:

$$\mathbb{E}_{q(\mathbf{z}|\mathbf{x}^{(i)})}\left[\log p(\mathbf{x}^{(i)}|\mathbf{z})\right] \approx \frac{1}{M}\sum_{i=1}^{M} \log\left(p(\mathbf{x}^{(i)}|\mathbf{z}^{(i,l)})\right)$$

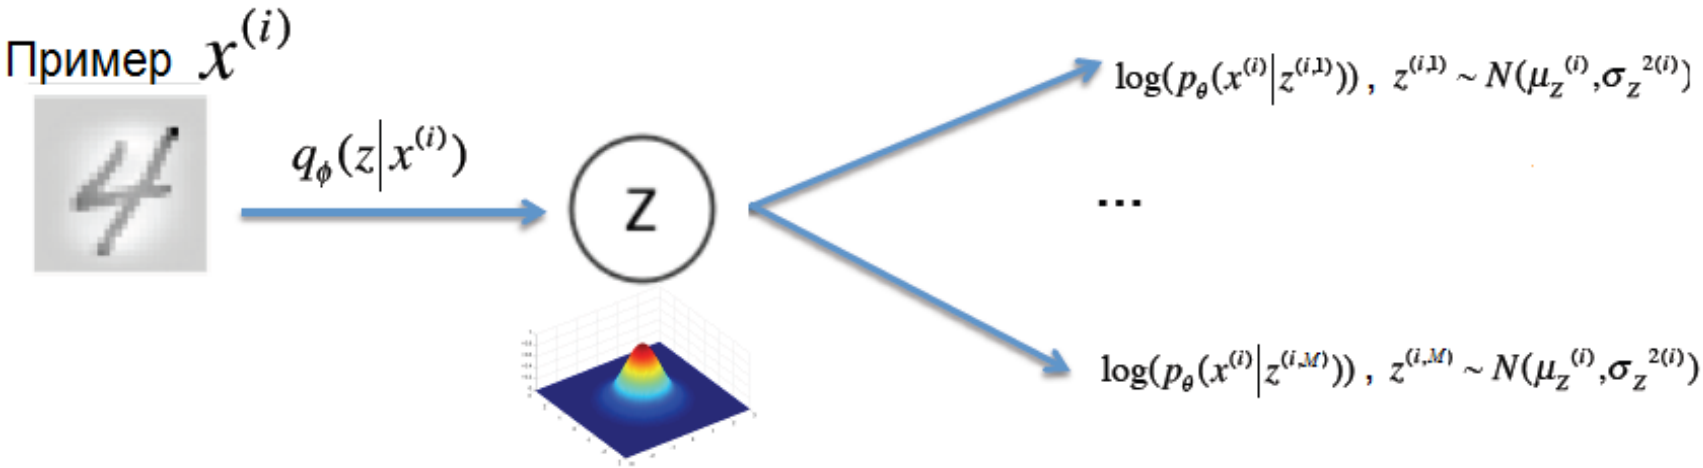

Репараметризация

- Обратное распространение невозможно при случайной генерации
- Используется прием репараметризации

$$\mathbf{z}^{(i,l)} \sim \mathcal{N}\left(\mu_{\mathbf{z}}^{(i)}, \sigma_{\mathbf{z}}^{(i)}\right) \rightarrow \mathbf{z}^{(i,l)} = \mu_{\mathbf{z}}^{(i)} + \sigma_{\mathbf{z}}^{(i)} \odot \varepsilon_i,\ \varepsilon_i \sim \mathcal{N}(0, 1)$$

- $\mathbf{z}$ имеет то же распределение, но теперь возможно обратное распространение, т.к. есть детерминированная часть и шум

Иллюстрация репараметризации

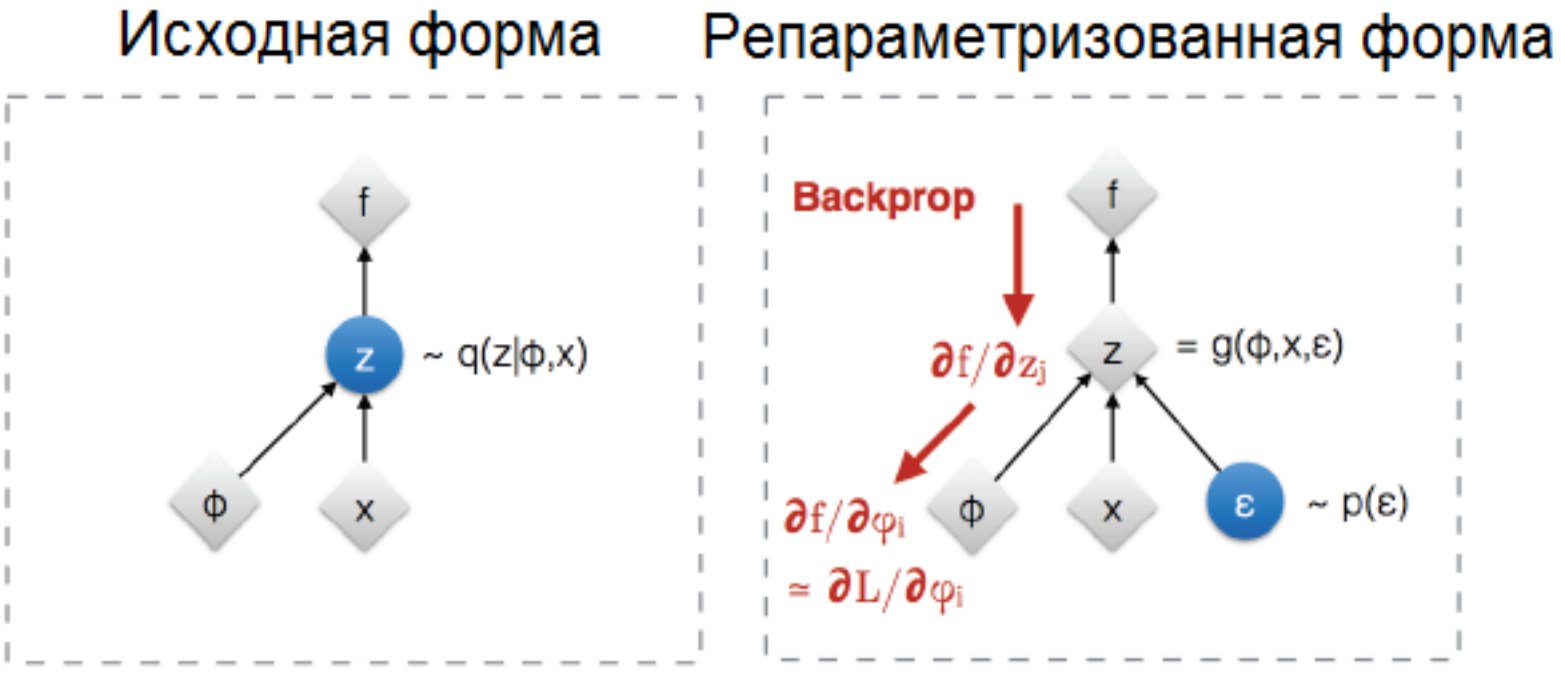

: Детерминированная вершина

: Случайная вершина

[Kingma, 2013]
[Bengio, 2013]
[Kingma and Welling 2014]
[Rezende et al 2014]

Объединяем все вместе

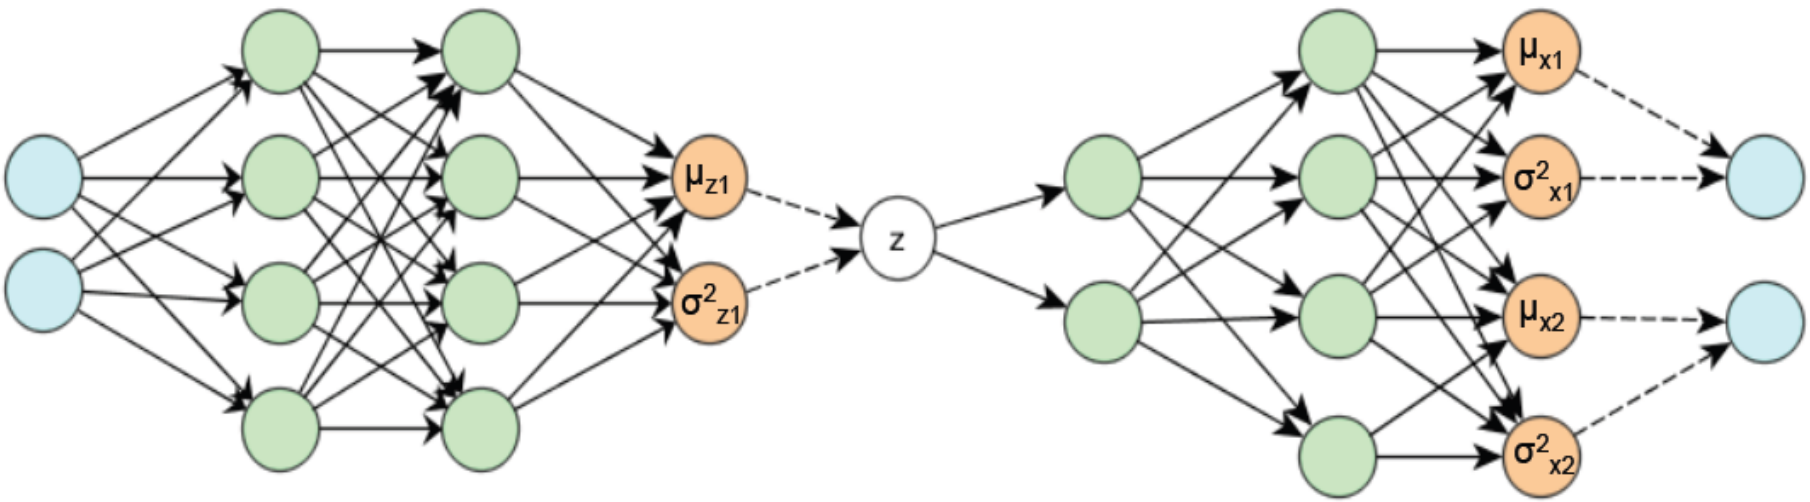

Объединяем все вместе

- **Регуляризация**: град. спуск, чтобы оптимизировать по $\mathbf{x}^{(i)}$

$$-KL(q(\mathbf{z}|\mathbf{x}^{(i)})||p(\mathbf{z})) = \frac{1}{2}\sum_{j=1}^{J}\left(1 + \log\left(\sigma_{\mathbf{z}_j}^{(i)2}\right) - \mu_{\mathbf{z}_j}^{(i)2} - \sigma_{\mathbf{z}_j}^{(i)2}\right)$$

- **Репродукция**: метод наим. квад. для постоянной дисперсии

$$-\log p(\mathbf{x}^{(i)}|\mathbf{z}^{(i)}) = \sum_{i=1}^{M}\frac{1}{2}\log\left(\sigma_{\mathbf{x}_i}^2\right) + \frac{\left(\mathbf{x}_j^{(i)} - \mu_{\mathbf{x}_j}\right)^2}{2\sigma_{\mathbf{x}_i}^2}$$

Вариационные методы и Deep Learning

- Deep learning - эффективный инструментарий для оптимизации, например, методом градиентного спуска, когда имеется огромное количество параметров и данных.
- Вариационные байесовские методы являются аппаратом, при помощи которого можно “переписать” задачи статистического вывода в виде задач оптимизации.
- Комбинация вариационных байесовских методов и Deep learning позволяет реализовать вывод на очень сложных апостериорных распределениях вероятностей.

Ресурсы и software

- Variational Autoencoder в TensorFlow: https://jmetzen.github.io/2015-11-27/vae.html
- Demo: http://www.dpkingma.com/sgvb_mnist_demo/demo.html

Соперничающие сети Generative adversarial networks (GAN)

Соперничающие сети - Generative adversarial networks (GAN)

Мотивация:

- Порождающие модели в основном обучаются при помощи метода максимума правдоподобия, котоый может быть неприменимым благодаря нормализации.
- Порождающая соперничающая сеть - это метод для обучения порождающих моделей при помощи нейронных сетей, обученных при помощи стохастического градиентного спуска вместо метода максимума правдоподобия.

Соперничающие сети

Две задачи в машинном обучении:

1. дискриминативная (discriminative): классифицирует входные данные
2. порождающая (generative): пытается создать модель, которая может генерировать данные, похожие на обучающие данные

Соперничающие сети

- Две сети:
  1. порождающая (generative): $y_G = G(z)$ - на входе z (шум), на выходе y_G
  2. дискриминативная (discriminative): $y_D = D(x)$ - на входе x (данные), на выходе y_D
- G-сеть должна научиться генерировать такие образцы y_G, что D-сеть D не сможет их отличить от эталонных образцов
- D-сеть должна научиться отличать эти сгенерированные образцы от настоящих

Данные и шум

x

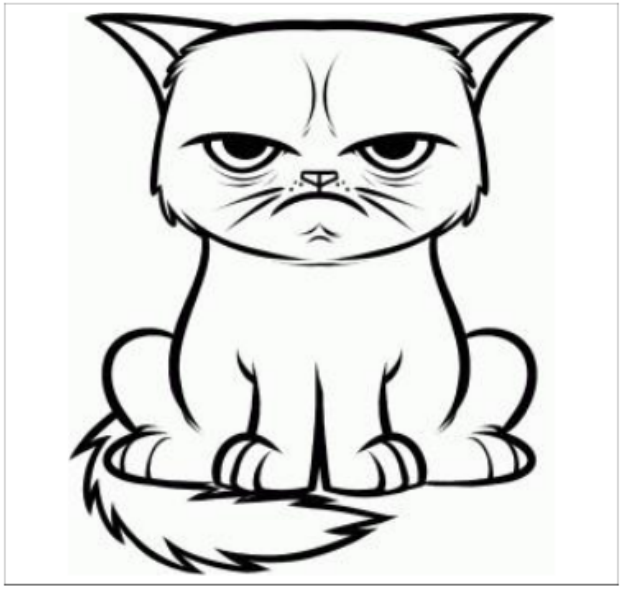

$G(z)$

http://www.lab41.org/lab41-reading-group-generative-adversarial-nets/

Соперничающие сети - две модели

- Две модели: порождающая (фальшивомонетчик) и дискриминативная (банкир)
- Фальшивомонетчик пытается построить на выходе подделку на настоящие деньги, а банкир — отличить подделку от оригинала (обе модели начинают с рандомных условий, и в начале выдают в качестве результатов шум).
- Цель фальшивомонетчика - сделать такой продукт, который банкир не мог бы отличить от настоящего.
- Цель банкира — максимально эффективно отличать подделки от оригиналов.
- Обе модели начинают игру друг против друга, где останется только один.

Соперничающие сети - обучение G-сети

- G-сеть: максимизация функционала $D(G(z))$, т.е. G-сеть максимизирует результат работы D-сети.
- G-сеть должна научиться для любого значения z на входе сгенерировать на выходе такое значение y_G, подав которое на вход D-сети, получим максимальное значение на ее выходе y_D (сделать так, чтобы банкир был уверен, что подделки — настоящие.)

Соперничающие сети - обучение G-сети

- Если на выходе D-сети стоит сигмоид, то она возвращает вероятность $D(x)$ того, что на вход сети подано “правильное” значение, т.е. G-сеть стремится максимизировать вероятность того, что D-сеть не отличит результат работы порождающей сети от “эталонных” образцов (а это означает, что порождающая сеть порождает правильные образцы).
- G-сеть учится по градиенту результата работы D-сети.

Соперничающие сети - обучение D-сети

- D-сеть учится два раза за одни шаг обучения: первый раз - на вход подается эталонный образец, а второй раз - результат G-сети.
- D-сеть: максимизация функционала $D(x)(1 - D(G(z)))$. Цель банкира - одновременно положительно опознавать оригиналы $D(x)$, и отрицательно - подделки $(1 - D(G(z)))$.
- D-сеть ничего не знает о том, что ей подано на вход: эталон или подделка. Об этом “знает” только функционал. Однако сеть учится в сторону градиента этого функционала.

Соперничающие сети - обучение D-сети

D-сеть: возвращает 1 для реального образа, 0 - для шума

$$D(\ \ ) = 1$$

$$D(\ \ ) = 0$$

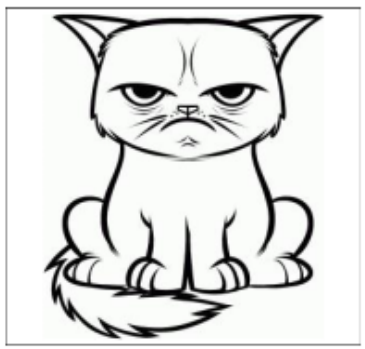

http://www.lab41.org/lab41-reading-group-generative-adversarial-nets/

Соперничающие сети - процесс обучения

1. На вход G-сети на каждом шаге подаются какие-то значения, например, совершенно случайные числа.
2. На вход D-сети на каждом шаге подается очередной эталонный образец и очередной результат работы G-сети.

Результат:

1. G-сеть должна научиться генерировать образцы как можно более близкие к эталонным.
2. D-сеть должна научиться отличать эталонные образцы от порожденных.

Возвращаясь к порождающим моделям (практика)

- Нейронная сеть обучается генерированием простых нормально распределенных $\mathcal{N}(-1, 1)$ сл.величин.
- На входе G одиночное случайное число из равномерного распределения шума: $z \sim \mathrm{uniform}(0, 1)$.
- Мы хотим, чтобы G отобразила точки $z_1, ..., z_M$ в $x_1, ..., x_M$ так, чтобы густота точек $x_i = G(z_i)$ соответствовала "сжатости" функции $p_{data}(X)$.
- Таким образом, G берет z и генерирует поддельные x'.

Возвращаясь к порождающим моделям (практика)

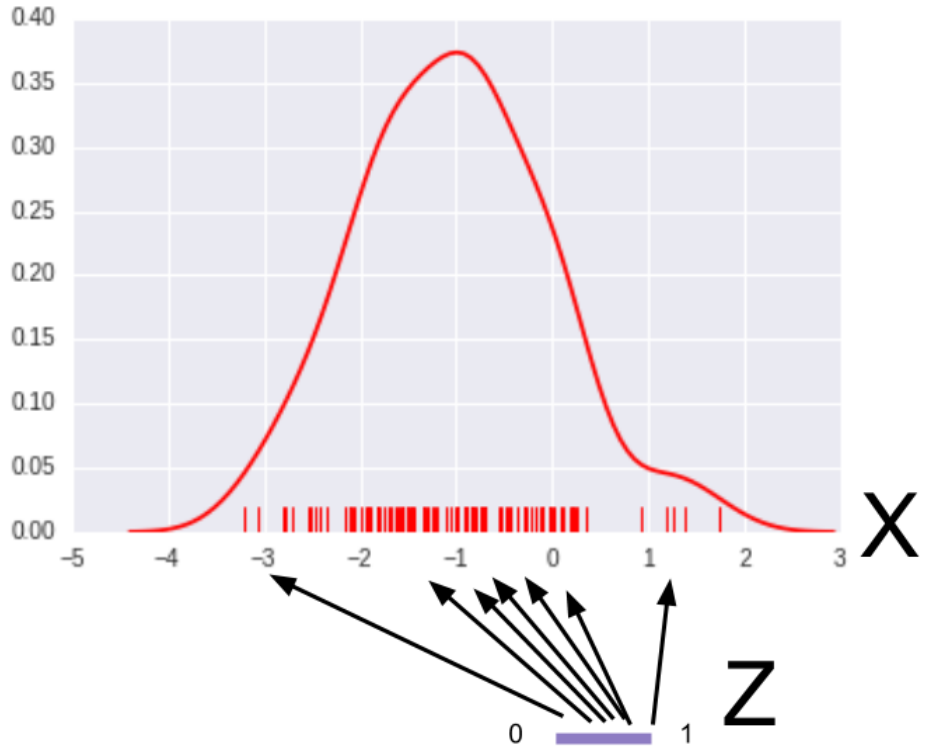

http://blog.evjang.com/2016_06_01_archive.html

Возвращаясь к порождающим моделям (практика)

Тем временем на вход дискриминатора D подается x и на выходе - вероятность того, что вход принадлежит p_{data}. Пусть D_1 и D_2 копии D (они разделяют одни и те же параметры $D_1(x) = D_2(x)$). Вход D_1 - один сгенерированный вектор из "истинного" распределения $x \sim p_{data}$ так, чтобы максимизировать $D_1(x)$. На входе D_2 - вектор x' (поддельный вектор, сгенерированный сетью G) так, что, для оптимизации D мы минимизируем $D_2(x')$.

Соперничающие автокодеры

Соперничающие автокодеры - Adversarial autoencoders

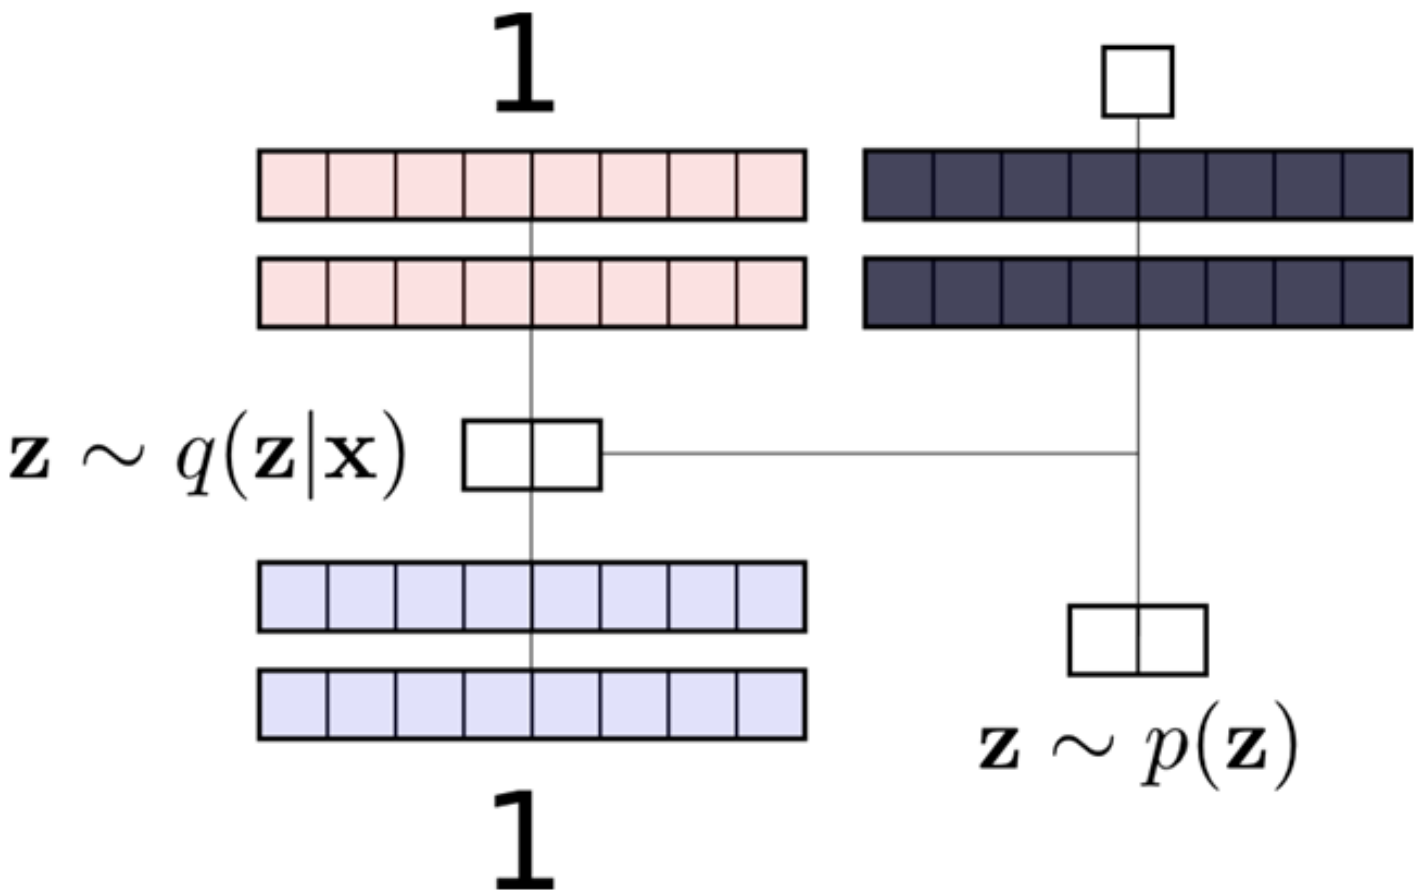

Соперничающие автокодеры

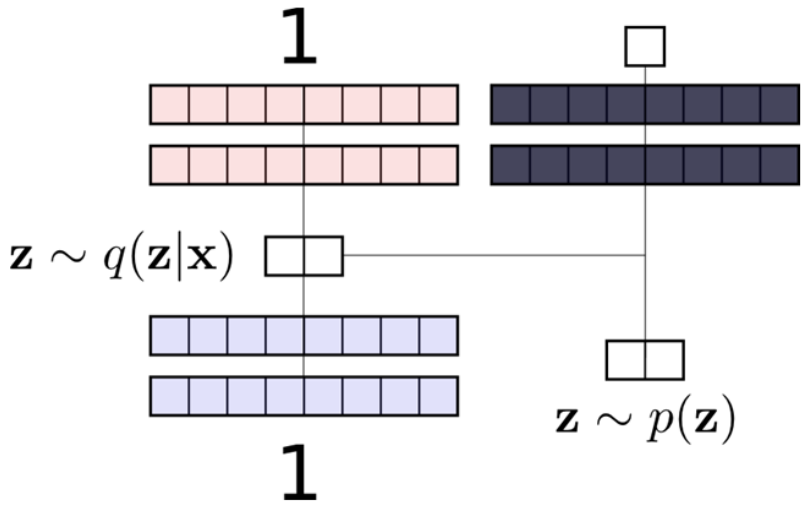

- Слева: входной вектор x (цифра “1”) преобразуется в код z кодером и поступает на декодер.
- Справа: выборочный вектор z генерируется в соответствии с априорным распределением $p(z)$. Дискриминатор оптимизируется, чтобы разделить выборки из $p(z)$ и из $q(z|x)$.

Соперничающие автокодеры

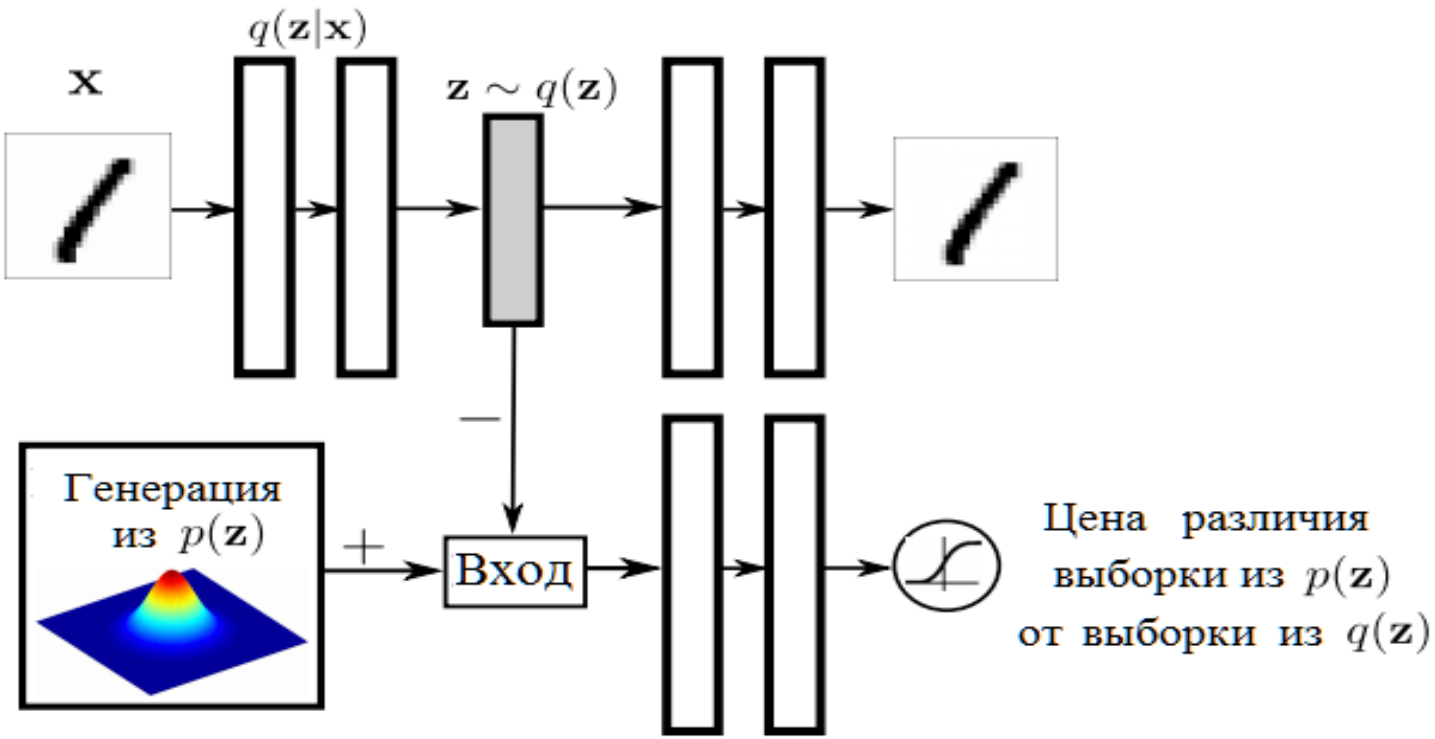

Соперничающие автокодеры

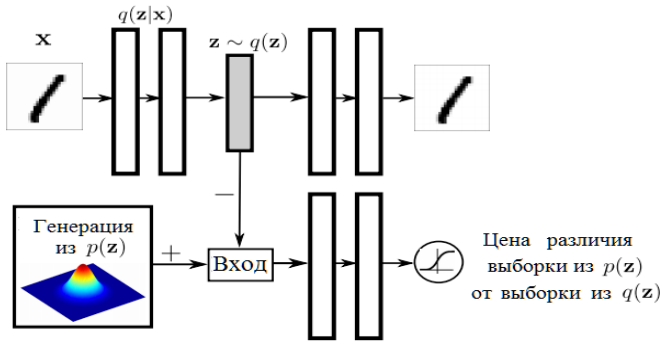

- Верхняя часть рисунка - вероятностный автокодер. Для данного входа x генерируется скрытый код z из кодирующего распределения $q(z|x)$ (моделируется как выход глубокой нейронной сети).
- В обычном автокодере этот кодер - детерминированный. Здесь он может быть вероятностным.
- Декодирующая сеть затем обучается, чтобы декодировать z и реконструировать исходный входной вектор x.
- Цель обучения - минимизация ошибки реконструкции (обычно квадратичная норма).

Соперничающие автокодеры

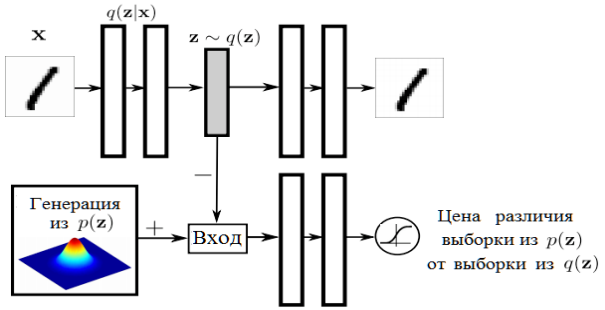

- Ошибка реконструкции обеспечивает то, что процесс кодирования сохраняет информацию о входном изображении, но она не осуществляет ничего другого, соответствующего скрытым векторам z.
- В общем, их распределение описывается как агрегированное апостериорное распределение $q(z) = \mathbb{E}_x q(z|x)$.

Соперничающие автокодеры

- Мы хотим, чтобы $q(z)$ совпадало с априорным $p(z)$. Это достигается введением дополнительного слагаемого в функцию потерь автокодера, который измеряет дивергенцию между q и p.
- Это можно сделать при помощи соперничающего обучения: обучаем разделяющую сеть, которая постоянно обучается, чтобы различать реальные кодовые векторы z, образованные кодированием реальных данных, от случайных кодовых векторов, сгенерированных из p. Если q почти полностью совпадает с p, то оптимальная разделяющая сеть должна иметь большую ошибку классификации.

Соперничающие автокодеры - события

Для каждого блока данных есть три события:

1. Блок входных векторов кодируется и декодируется, после чего сеть модифицируется на основе стандартной ошибки реконструирования.
2. Блок входных векторов преобразуется кодером, после чего он соединятся с вектором, сгенерированным из априорного распределения $p(z)$. Дискриминатор затем модифицируется, используя двоичный кросс-энтропийный функционал потерь, основанный его способности разделять эти два вектора.

Соперничающие автокодеры - события (продолжение)

3. Блок входных векторов преобразуется кодером, источник этих данных прогнозируется дискритминатором, и генератор (кодер) модифицируется, используя двоичный кросс-энтропийный функционал потерь, основанный на способности “обмануть” дискриминатор в предположении, что данные - из априорного распределения.

Соперничающие автокодеры и сверточная сеть

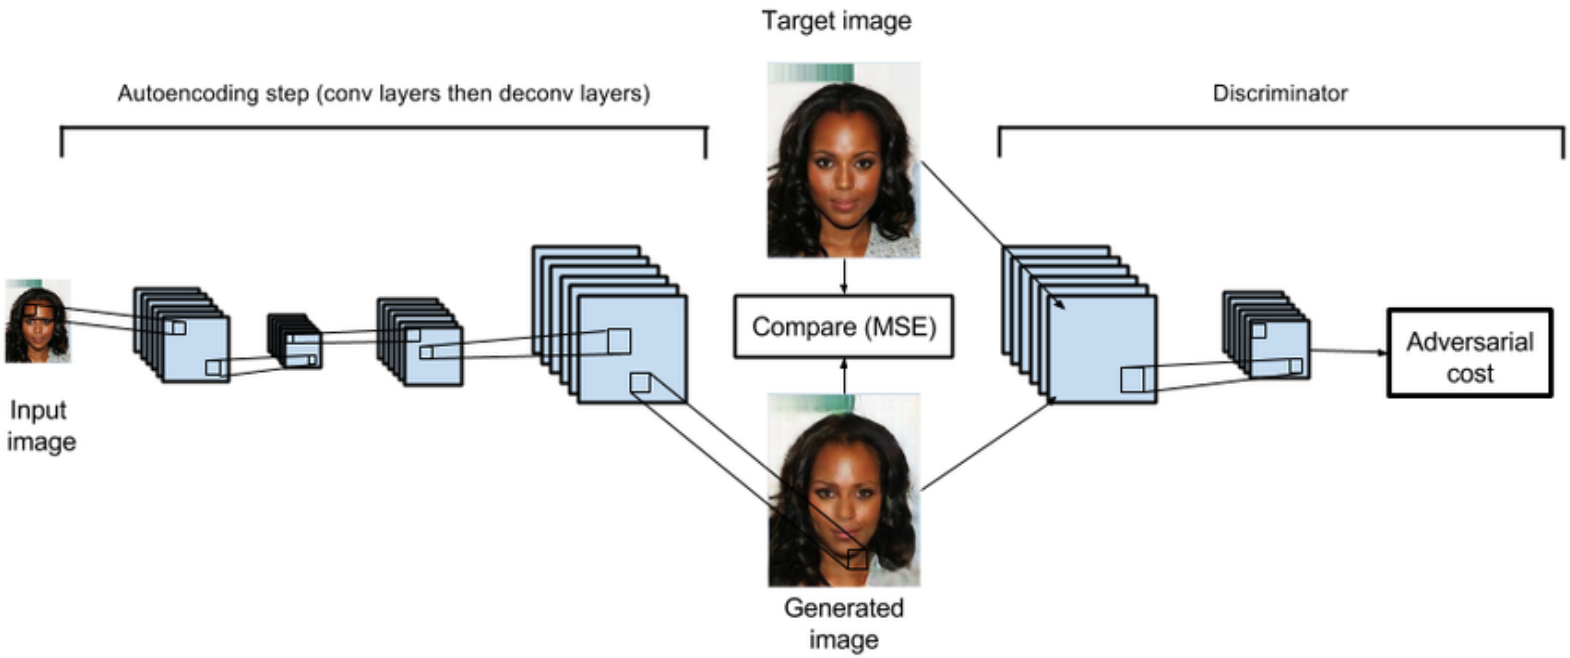

https://swarbrickjones.wordpress.com/2016/01/24/generative-adversarial-autoencoders-in-theano/

Вопросы

?