

КАК ОБУЧАТЬ НЕЙРОННЫЕ СЕТИ


Сергей Николенко

ИТМО — Санкт-Петербург

21 сентября 2026 г.

Random facts:

- 21 сентября 862 г. новгородцы призвали на княжение братьев-варягов Рюрика, Синеуса и Трувора
- 21 сентября 1348 г. евреи Цюриха обвинены в отравлении родников, а 21 сентября 1451 г. евреям Голландии было предписано носить на одежде опознавательные знаки
- 21 сентября 1745 г. состоялось первое сражение восстания якобитов: в битве при Престонпасе якобиты рассеяли английскую армию менее чем за двадцать минут
- 21 сентября 1937 г. в издательстве George Allen & Unwin вышла повесть Дж. Р. Р. Толкина «The Hobbit, or There and Back Again»
- 21 сентября в России — День коллекционера, отмечавшийся с конца 1950-х как День почтовой марки и коллекционера
- 21 сентября 1898 г. императрица Цыси захватила власть в Японии в результате дворцового переворота, закончив Сто дней реформ императора Айсиньгёро Цзайтяня




- В прошлый раз мы прошли путь от механических автоматов до перцептрона и вспомнили байесовский вывод: монетку, линейную и логистическую регрессию.
- Мы уже знаем, что такое один нейрон и что логистическая регрессия — это ровно он и есть.
- Сегодня разберёмся, как из нейронов собрать сеть и, главное, как её обучить:
 - (1) функции активации — чем заменить сигмоиду и почему;
 - (2) от перцептрона к сети, граф вычислений, backpropagation;
 - (3) варианты градиентного спуска — от импульса до Adam;
 - (4) и общие сюжеты: регуляризация и дропаут, инициализация весов, нормализация по мини-батчам.
- Материала много; что не успеем, перенесём на следующий раз.

Один перцептрон: функции активации

ФУНКЦИИ АКТИВАЦИИ

- Есть много разных нелинейных функций, которые можно использовать в перцептроне.
- Логистический сигмоид:


$$\sigma(x) = \frac{1}{1 + e^{-x}}.$$



- Гиперболический тангенс:


$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$

- Очень похоже, но ноль не является точкой насыщения.




- Ступенька (функция Хевисайда):

$$\text{step}(x) = \begin{cases} 0, & \text{if } x < 0, \\ 1, & \text{if } x > 0. \end{cases}$$




- Rectified linear unit (ReLU):

$$\text{ReLU}(x) = \begin{cases} 0, & \text{if } x < 0, \\ x, & \text{if } x \geq 0. \end{cases}$$



- Математическая мотивация для ReLU:


$$\sigma\left(x + \frac{1}{2}\right) + \sigma\left(x - \frac{1}{2}\right) + \sigma\left(x - \frac{3}{2}\right) + \sigma\left(x - \frac{5}{2}\right) + \dots$$



ФУНКЦИИ АКТИВАЦИИ


- Биологическая мотивация для ReLU:

$$f(I) = \begin{cases} \left(\tau \log \frac{E+RI-V_{\text{reset}}}{E+RI-V_{th}} \right)^{-1}, & \text{if } E+RI > V_{th}, \\ 0, & \text{if } E+RI \leq V_{th}, \end{cases}$$




- Несколько вариантов ReLU — Leaky ReLU и Parametric ReLU:

$$\text{LReLU}(x) = \begin{cases} ax, & \text{if } x < 0, \\ x, & \text{if } x > 0. \end{cases}$$



- Exponential LU:

$$\text{ELU}(x) = \begin{cases} \alpha (e^x - 1), & x < 0, \\ x, & x \geq 0. \end{cases}$$




- Обычно ReLU хорошо работает, но последнего слова ещё не сказано.

ФУНКЦИИ АКТИВАЦИИ

- Но история только начинается. Ramachandran et al. (2017) сделали поиск по пространству функций и нашли *Swish*:

$$\text{Swish}(x) = x\sigma(\beta x) = \frac{x}{1 + e^{-\beta x}}$$

- (Misra, 2019): $\text{Mish}(x) = x \tanh(\text{softplus}(x)) = x \tanh(\ln(1 + e^x))$



- Очень интересная работа вышла в сентябре 2020 года...
- (Ma et al., 2020): давайте рассмотрим гладкое обобщение максимума

$$S_{\beta}(x_1, \dots, x_n) = \frac{\sum_{i=1}^n x_i e^{\beta x_i}}{\sum_{i=1}^n e^{\beta x_i}}.$$

- И давайте подставим туда две функции от x , т.е. жёсткому максимуму $\max(g(x), h(x))$ будет соответствовать

$$\begin{aligned} S_{\beta}(g(x), h(x)) &= g(x) \frac{e^{\beta g(x)}}{e^{\beta g(x)} + e^{\beta h(x)}} + h(x) \frac{e^{\beta h(x)}}{e^{\beta g(x)} + e^{\beta h(x)}} = \\ &= g(x) \sigma(\beta(g(x) - h(x))) + h(x) \sigma(\beta(h(x) - g(x))) = \\ &= (g(x) - h(x)) \sigma(\beta(g(x) - h(x))) + h(x). \end{aligned}$$

- Ma et al. называли это *ActivateOrNot* (ACON). Теперь это обобщает всё на свете:

- для $g(x) = x$ и $h(x) = 0$ жёсткий максимум будет $\text{ReLU}(x) = \max(x, 0)$, а гладкий максимум

$$f_{\text{ACON-A}}(x, 0) = S_{\beta}(x, 0) = x\sigma(\beta x),$$

т.е. в точности *Swish*!

- для $g(x) = x$ и $h(x) = ax$ при некотором $a < 1$, жёсткий максимум будет $\text{LReLU}(x) = \max(x, px)$, а гладкий максимум

$$f_{\text{ACON-B}} = S_{\beta}(x, ax) = (1 - a)x\sigma(\beta(1 - a)x) + ax;$$

- Ma et al. называли это *ActivateOrNot* (ACON). Теперь это обобщает всё на свете:
 - и это можно прямолинейно обобщить до


$$f_{ACON-C} = S_{\beta}(a_1x, a_2x) = (a_1 - a_2)x\sigma(\beta(a_1 - a_2)x) + a_2x;$$

теперь a_1 и a_2 могут стать обучаемыми параметрами, а интуитивно это просто пределы производной с двух сторон:

$$\lim_{x \rightarrow \infty} \frac{df_{ACON-C}}{dx} = a_1, \quad \lim_{x \rightarrow -\infty} \frac{df_{ACON-C}}{dx} = a_2.$$


ФУНКЦИИ АКТИВАЦИИ

- Вот так выглядит ACON-C для разных значений параметров:



ФУНКЦИИ АКТИВАЦИИ

- Пишут, что подбором параметров можно очень много выгадать даже в самых стандартных избитых задачах:



- Но как-то с тех пор не произошло революции...
- Это частая история в DL.

- Есть ли градиентный спуск в настоящих нейронах?
- Скорее всего нет (увидим позже почему).
- Хотя у Хинтона есть интересный доклад об этом... но всё-таки вряд ли.
- *Обучение по Хеббу* – neurons that fire together, wire together:

$$\Delta w_i = \eta x_i x_j.$$

- В ML привело к *сетям Хопфилда*, которые вроде как реализуют ассоциативную память, но плохо.
- Новая тема: *spike-timing-dependent plasticity* (STDP), т.е. насколько спайки зависят от временных свойств сигналов.


ОТ ПЕРЦЕПТРОНА К НЕЙРОННОЙ СЕТИ

Суть происходящего

- Вообще говоря, всё, что мы делаем в машинном обучении, — это аппроксимация и оптимизация функций.
- Например:
 - есть функция из картинок в то, что на них изображено;
 - ещё проще: бинарная функция из пикселей картинки в «котик или не котик»;
 - функция, мягко скажем, довольно сложная; задана в виде датасета; как нам её реализовать?
- Обычный подход в машинном обучении:
 - строим какой-то класс моделей, обычно параметрический;
 - и подгоняем параметры так, чтобы модель хорошо описывала данные;
 - то есть оптимизируем какую-то функцию ошибки или функцию качества (правдоподобие, апостериорную вероятность).
- Нейронные сети — это очень мощный и гибкий класс таких моделей.
- Сложность в том, как же обучить их параметры.


- Итак, в машинном обучении много разных задач, с учителем и без.
- Их обычно решают по теореме Байеса, пересчитывая наши представления о параметрах в зависимости от полученных данных.
- Для этого обычно надо оптимизировать какую-нибудь сложную функцию (например, апостериорное распределение).
- И для невыпуклых функций это обычно делают тем или иным вариантом *градиентного спуска*.

- Градиентный спуск — главный и фактически единственный способ оптимизации очень сложных функций.



- Берём градиент $\nabla E(\mathbf{w})$, сдвигаемся немножко, повторяем.

- Основной компонент нейронной сети – *перцептрон*:



- Линейная комбинация входов, потом нелинейность:

$$y = h(\mathbf{w}^\top \mathbf{x}) = h \left(\sum_i w_i x_i \right).$$

- Обучение *градиентным спуском*.
- Для исходного перцептрона Розенблатта ($h = \text{id}$):

$$E_P(\mathbf{w}) = - \sum_{\mathbf{x} \in \mathcal{M}} y(\mathbf{x}) (\mathbf{w}^\top \mathbf{x}),$$

$$\mathbf{w}^{(\tau+1)} = \mathbf{w}^{(\tau)} - \eta \nabla_{\mathbf{w}} E_P(\mathbf{w}) = \mathbf{w}^{(\tau)} + \eta t_n \mathbf{x}_n.$$


- Или, к примеру, можно делать классификацию, подставляя в качестве функции активации логистический сигмоид $h(x) = \sigma(x) = \frac{1}{1+e^{-x}}$:

$$E(\mathbf{w}) = -\frac{1}{N} \sum_{i=1}^N (y_i \log \sigma(\mathbf{w}^\top \mathbf{x}_i) + (1 - y_i) \log (1 - \sigma(\mathbf{w}^\top \mathbf{x}_i))).$$

- По сути это просто логистическая регрессия.


ОБЪЕДИНЯЕМ ПЕРЦЕПТРОНЫ В СЕТЬ

- Сеть перцептронов; выходы одних – входы других.
- Hornik, 1990: двух уровней достаточно для приближения любой функции.
- Но глубокие сети эффективнее — distributed representations:



Объединяем перцептроны в сеть

- Обычно нейронные сети организованы в *слои*.
- Это очень естественно и легко параллелизуется.



- Но по сути мы приближаем очень сложную функцию большой композицией простых функций.
- Как теперь её обучить?
- Ответ прост: градиентный спуск. Но есть и сложности.

ГРАДИЕНТНЫЙ СПУСК И ГРАФЫ ВЫЧИСЛЕНИЙ

- Градиентный спуск: считаем градиент относительно весов, двигаемся в нужном направлении.
- Формально: для функции ошибки E , целевых значений y и модели f с параметрами θ :

$$E(\theta) = \sum_{(\mathbf{x}, y) \in D} E(f(\mathbf{x}, \theta), y),$$

$$\theta_t = \theta_{t-1} - \eta \nabla E(\theta_{t-1}) = \theta_{t-1} - \eta \sum_{(\mathbf{x}, y) \in D} \nabla E(f(\mathbf{x}, \theta_{t-1}), y).$$


- То есть надо по всему датасету пройти, чтобы хоть куда-то сдвинуться?..

- Нет, конечно — *стохастический градиентный спуск* обновляет после каждого примера:

$$\theta_t = \theta_{t-1} - \eta \nabla E(f(\mathbf{x}_t, \theta_{t-1}), y_t),$$

- А на практике обычно используют *мини-батчи*, их легко параллелизовать и они сглаживают излишнюю “стохастичность”.
- Пока что единственный реальный параметр – это скорость обучения η .


- Со скоростью обучения η масса проблем:




- Мы вернёмся к ним позже, а пока поговорим о производных.

ГРАФ ВЫЧИСЛЕНИЙ, FROP AND BPROP


- Представим функцию как композицию простых функций (т.е. таких, от которых можно производную взять).
- Пример: $f(x, y) = x^2 + xy + (x + y)^2$:



(a)



(б)



(B)

- Градиент теперь можно взять по правилу дифференцирования сложной функции (chain rule):

$$(f \circ g)'(x) = (f(g(x)))' = f'(g(x))g'(x).$$

- По сути это значит, что небольшое изменение δx приводит к

$$\delta f = f'(g(x))\delta g = f'(g(x))g'(x)\delta x.$$

- Нам нужно только уметь брать *градиенты*, т.е. производные по векторам:

$$\nabla_{\mathbf{x}} f = \begin{pmatrix} \frac{\partial f}{\partial x_1} \\ \vdots \\ \frac{\partial f}{\partial x_n} \end{pmatrix}.$$

$$\nabla_{\mathbf{x}}(f \circ g) = \begin{pmatrix} \frac{\partial f \circ g}{\partial x_1} \\ \vdots \\ \frac{\partial f \circ g}{\partial x_n} \end{pmatrix} = \begin{pmatrix} \frac{\partial f}{\partial g} \frac{\partial g}{\partial x_1} \\ \vdots \\ \frac{\partial f}{\partial g} \frac{\partial g}{\partial x_n} \end{pmatrix} = \frac{\partial f}{\partial g} \nabla_{\mathbf{x}} g.$$

- А если f зависит от x несколько раз,
 $f = f(g_1(x), g_2(x), \dots, g_k(x))$, δx тоже несколько раз
появляется:


$$\frac{\partial f}{\partial x} = \frac{\partial f}{\partial g_1} \frac{\partial g_1}{\partial x} + \dots + \frac{\partial f}{\partial g_k} \frac{\partial g_k}{\partial x} = \sum_{i=1}^k \frac{\partial f}{\partial g_i} \frac{\partial g_i}{\partial x}.$$

$$\nabla_{\mathbf{x}} f = \frac{\partial f}{\partial g_1} \nabla_{\mathbf{x}} g_1 + \dots + \frac{\partial f}{\partial g_k} \nabla_{\mathbf{x}} g_k = \sum_{i=1}^k \frac{\partial f}{\partial g_i} \nabla_{\mathbf{x}} g_i.$$

- Это матричное умножение на матрицу Якоби:


$$\nabla_{\mathbf{x}} f = \nabla_{\mathbf{x}} \mathbf{g} \nabla_{\mathbf{g}} f, \text{ где } \nabla_{\mathbf{x}} \mathbf{g} = \begin{pmatrix} \frac{\partial g_1}{\partial x_1} & \dots & \frac{\partial g_k}{\partial x_1} \\ \vdots & & \vdots \\ \frac{\partial g_1}{\partial x_n} & \dots & \frac{\partial g_k}{\partial x_n} \end{pmatrix}.$$

- Возвращаемся к примеру:




ГРАФ ВЫЧИСЛЕНИЙ, FROP AND BPROP

- Прямое распространение (forward propagation, fprop):
вычисляем $\frac{\partial f}{\partial x}$ как сложную функцию.




- Обратное распространение (backpropagation, backprop):
начинаем от конца и идём как $\frac{\partial f}{\partial g} = \sum_{g' \in \text{Children}(g)} \frac{\partial f}{\partial g'} \frac{\partial g'}{\partial g}$.



- Backprop гораздо лучше: получаем все производные за один проход по графу.
- Вот и всё! Теперь мы можем считать градиенты от любых, сколь угодно сложных функций; нужно только, чтобы они представлялись как композиции простых.
- А это всё, что нужно для градиентного спуска!!
- Библиотеки *pyTorch*, *TensorFlow*, *theano* — это на самом деле библиотеки для автоматического дифференцирования, это их основная функция.
- И теперь мы можем реализовать массу “классических” моделей в *pyTorch* и обучить их градиентным спуском.
- А у живых нейронов, кстати, не получается, потому что нужно два разных “алгоритма” для вычисления самой функции и градиента.

ГРАФ ВЫЧИСЛЕНИЙ, FROP AND BPROP

- Если сеть организована в слои, то fprop и backprop можно векторизовать, т.е. представить в виде матричных операций.



w_{jk}^l is the weight from the k^{th} neuron in the $(l-1)^{\text{th}}$ layer to the j^{th} neuron in the l^{th} layer

- Обозначим $w_{jk}^{(l)}$ вес связи от k -го нейрона слоя $(l-1)$ к j -му нейрону слоя l .

- Обозначим $w_{jk}^{(l)}$ вес связи от k -го нейрона слоя $(l - 1)$ к j -му нейрону слоя l .
- Также $b_j^{(l)}$ – bias j -го нейрона, $a_j^{(l)}$ – его активация, т.е.

$$a_j^{(l)} = h \left(\sum_k w_{jk}^{(l)} a_k^{(l-1)} + b_j^{(l)} \right).$$

- Это можно записать в векторной форме:

$$\mathbf{a}^{(l)} = h \left((\mathbf{w}^{(l)})^\top \mathbf{a}^{(l-1)} + \mathbf{b}^{(l)} \right) = h \left(\mathbf{z}^{(l)} \right).$$

- А наша цель – посчитать производные функции ошибки по всем переменным: $\frac{\partial C}{\partial w_{jk}^{(l)}}, \frac{\partial C}{\partial b_j^{(l)}}$.

- Определяем ошибку j -го нейрона в слое l :

$$\delta_j^{(l)} = \frac{\partial C}{\partial z_j^{(l)}}.$$

- И backprop теперь можно делать от последнего уровня L ко входу, сразу в векторном виде:

$$\delta_j^{(L)} = \frac{\partial C}{\partial a^{(L)}} h' \left(z_j^{(L)} \right), \text{ т.е. } \delta^{(L)} = \nabla_{\mathbf{a}^{(L)}} C \odot h' \left(\mathbf{z}^{(L)} \right),$$

$$\delta^{(l)} = \left((W^{(l+1)})^\top \delta^{(l+1)} \right) \odot h' \left(\mathbf{z}^{(l)} \right),$$

$$\frac{\partial C}{\partial b_j^{(l)}} = \delta_j^{(l)},$$

$$\frac{\partial C}{\partial w_{jk}^{(l)}} = a_k^{(l-1)} \delta_j^{(l)}.$$

- Это всё операции, которые легко параллелизовать на GPU.

- Backpropagation – идея со сложной судьбой.
- Конечно, это просто расчёт градиентов для градиентного спуска.
- Так что уже в 1960-х было понятно, как тащить производные динамическим программированием (и тем более удивительно насчёт Minsky, Papert).
- В явном виде полностью BP для нейронных сетей – M.Sc. thesis (Linnainmaa, 1970).
- (Hinton, 1974) – переоткрыл backprop, популяризовал.
- Rumelhart, Hinton, Williams, “Learning representations by back-propagating errors” (Nature, 1986).

ВАРИАНТЫ ГРАДИЕНТНОГО СПУСКА

- «Ванильный» градиентный спуск:

$$\mathbf{x}_k = \mathbf{x}_{k-1} - \alpha \nabla f(\mathbf{x}_k).$$

- Всё зависит от скорости обучения α .
- Первая мысль — пусть α уменьшается со временем:
 - линейно (linear decay):

$$\alpha = \alpha_0 \left(1 - \frac{t}{T}\right);$$

- или экспоненциально (exponential decay):

$$\alpha = \alpha_0 e^{-\frac{t}{T}}.$$

- Об этом есть большая наука. Например, условия Вольфе (Wolfe conditions): если мы решаем задачу минимизации $\min_{\mathbf{x}} f(\mathbf{x})$, и на шаге k уже нашли направление $\mathbf{p}_k$, в котором двигаться (например, $\mathbf{p}_k = \nabla_{\mathbf{x}} f(\mathbf{x}_k)$), т.е. надо решить $\min_{\alpha} f(\mathbf{x}_k + \alpha \mathbf{p}_k)$, то:
 - для $\phi_k(\alpha) = f(\mathbf{x}_k + \alpha \mathbf{p}_k)$ будет $\phi'_k(\alpha) = \nabla f(\mathbf{x}_k + \alpha \mathbf{p}_k)^{\top} \mathbf{p}_k$, и если $\mathbf{p}_k$ – направление спуска, то $\phi'_k(0) < 0$;
 - шаг α должен удовлетворять условиям Армико (Armijo rule):

$$\phi_k(\alpha) \leq \phi_k(0) + c_1 \alpha \phi'_k(0) \text{ для некоторого } c_1 \in (0, \frac{1}{2});$$

- или даже более сильным условиям Вульфа (Wolfe rule): Армико плюс


$$|\phi'_k(\alpha)| \leq c_2 |\phi'_k(0)|,$$

т.е. мы хотим уменьшить проекцию градиента.


- Останавливаем когда $\|\nabla_{\mathbf{x}} f(\mathbf{x}_k)\|^2 \leq \epsilon$ или $\|\nabla_{\mathbf{x}} f(\mathbf{x}_k)\|^2 \leq \epsilon \|\nabla_{\mathbf{x}} f(\mathbf{x}_0)\|^2$ (а почему квадрат, кстати?).

ГРАДИЕНТНЫЙ СПУСК


- Давайте посмотрим, что происходит, если масштаб разный:
для функции $f(x, y) = \frac{1}{2}x^2 + \frac{\rho}{2}y^2 \rightarrow \min_{x,y}$



$\rho = 0.5$



$\rho = 0.1$



$\rho = 0.01$

- Для вытянутых «долин» (переменных с разным масштабированием) мы сразу получаем кучу лишних итераций, очень медленно.
- Лучше быть *адаптивным*; как это сделать?

- Лучше всего, конечно, *метод Ньютона*: давайте отмасштабируем обратно при помощи гессиана

$$\mathbf{g}_k = \nabla_{\mathbf{x}} f(\mathbf{x}_k), \quad H_k = \nabla_{\mathbf{x}}^2 f(\mathbf{x}_k), \quad \text{и} \quad \mathbf{x}_{k+1} = \mathbf{x}_k - \alpha_k H_k^{-1} \mathbf{g}_k.$$

- Здесь тоже применимо условие Армихо:

$$\alpha_k : \quad f(\mathbf{x}_{k+1}) \leq f(\mathbf{x}_k) - c_1 \alpha_k \mathbf{g}_k^\top H_k^{-1} \mathbf{g}_k, \quad c_1 \approx 10^{-4}.$$

- Было бы круто! Но H_k посчитать просто нереально.

- Есть, правда, приближения.
- Метод сопряжённых градиентов, квази-ньютоновские методы...
- L-BFGS (limited memory Broyden–Fletcher–Goldfarb–Shanno):
 - строим аппроксимацию к H^{-1} ;
 - для этого сохраняем последовательно апдейты аргументов функции и градиентов и выражаем через них H^{-1} .
- Интересный открытый вопрос: можно ли заставить L-BFGS работать для deep learning?
- Но пока не получается, в основном потому, что всё-таки нужно уметь считать градиент.
- А ведь у нас обычно нет возможности даже градиент вычислить...

СТОХАСТИЧЕСКИЙ ГРАДИЕНТНЫЙ СПУСК

- У нас обычно стохастический градиентный спуск:

$$\mathbf{x}_t = \mathbf{x}_{t-1} - \alpha \nabla f(\mathbf{x}_t, \mathbf{x}_{t-1}, y_t).$$

- Да ещё и с мини-батчами; как это понять формально?
- Мы обычно решаем задачу *стохастической оптимизации*:

$$F(\mathbf{x}) = \mathbb{E}_{q(\mathbf{y})} f(\mathbf{x}, \mathbf{y}) \rightarrow \min_{\mathbf{x}} :$$

- минимизация эмпирического риска

$$F(\mathbf{x}) = \frac{1}{N} \sum_{i=1}^N f_i(\mathbf{x}) = \mathbb{E}_{i \sim U(1, \dots, N)} f_i(\mathbf{x}) \rightarrow \min_{\mathbf{x}};$$

- минимизация вариационной нижней оценки (ELBO)... но об этом позже.
- Что такое теперь, получается, мини-батчи?


- Да просто эмпирические оценки общей функции по подвыборке:

$$\hat{F}(\mathbf{x}) = \frac{1}{m} \sum_{i=1}^m f(\mathbf{x}, \mathbf{y}_i), \quad \hat{\mathbf{g}}(\mathbf{x}) = \frac{1}{m} \sum_{i=1}^m \nabla_{\mathbf{x}} f(\mathbf{x}, \mathbf{y}_i).$$


- Это очень хорошие оценки: несмещённые, сходятся на бесконечности (правда, медленно), легко посчитать.
- В целом, так и мотивируется стохастический градиентный спуск (SGD): метод Монте-Карло по сути.
- Но есть проблемы...

СТОХАСТИЧЕСКИЙ ГРАДИЕНТНЫЙ СПУСК

- Проблемы SGD:
 - никогда не идёт в правильном направлении,
 - шаг не равен нулю в оптимуме $F(\mathbf{x})$, т.е. не может сойтись с постоянной длиной шага,
 - мы не знаем ни $F(\mathbf{x})$, ни $\nabla F(\mathbf{x})$, т.е. не можем использовать правила Армихо и Вульфа.



SGD trajectory



optimum vicinity

- Тем не менее, можно попробовать проанализировать итерацию SGD для $F(\mathbf{x}) = \mathbb{E}_{q(\mathbf{y})} f(\mathbf{x}, \mathbf{y}) \rightarrow \min_{\mathbf{x}}$:

$$\mathbf{x}_{k+1} = \mathbf{x}_k - \alpha_k \hat{\mathbf{g}}_k, \quad \mathbb{E} \hat{\mathbf{g}}_k = \mathbf{g}_k = \nabla F(\mathbf{x}_k).$$

- Давайте оценим невязку точки на очередной итерации:

$$\begin{aligned} \|\mathbf{x}_{k+1} - \mathbf{x}_{\text{opt}}\|^2 &= \|\mathbf{x}_k - \alpha_k \hat{\mathbf{g}}_k - \mathbf{x}_{\text{opt}}\|^2 = \\ &= \|\mathbf{x}_k - \mathbf{x}_{\text{opt}}\|^2 - 2\alpha_k \hat{\mathbf{g}}_k^\top (\mathbf{x}_k - \mathbf{x}_{\text{opt}}) + \alpha_k^2 \|\hat{\mathbf{g}}_k\|^2. \end{aligned}$$


- Возьмём ожидание по $q(\mathbf{y})$ в момент времени k :

$$\mathbb{E} \|\mathbf{x}_{k+1} - \mathbf{x}_{\text{opt}}\|^2 = \|\mathbf{x}_k - \mathbf{x}_{\text{opt}}\|^2 - 2\alpha_k \mathbf{g}_k^\top (\mathbf{x}_k - \mathbf{x}_{\text{opt}}) + \alpha_k^2 \mathbb{E} \|\hat{\mathbf{g}}_k\|^2.$$

СТОХАСТИЧЕСКИЙ ГРАДИЕНТНЫЙ СПУСК

- Для простоты предположим, что F выпуклая:

$$F(\mathbf{x}_{\text{opt}}) \geq F(\mathbf{x}_k) + \mathbf{g}_k^\top (\mathbf{x}_k - \mathbf{x}_{\text{opt}})$$



- У нас было

$$\begin{aligned}\mathbb{E}\|\mathbf{x}_{k+1} - \mathbf{x}_{\text{opt}}\|^2 &= \|\mathbf{x}_k - \mathbf{x}_{\text{opt}}\|^2 - 2\alpha_k \mathbf{g}_k^\top (\mathbf{x}_k - \mathbf{x}_{\text{opt}}) + \alpha_k^2 \mathbb{E}\|\hat{\mathbf{g}}_k\|^2, \\ F(\mathbf{x}_{\text{opt}}) &\geq F(\mathbf{x}_k) + \mathbf{g}_k^\top (\mathbf{x}_k - \mathbf{x}_{\text{opt}}).\end{aligned}$$

- Значит,

$$\begin{aligned}\alpha_k (F(\mathbf{x}_k) - F(\mathbf{x}_{\text{opt}})) &\leq \alpha_k \mathbf{g}_k^\top (\mathbf{x}_k - \mathbf{x}_{\text{opt}}) = \\ &= \frac{1}{2} \|\mathbf{x}_k - \mathbf{x}_{\text{opt}}\|^2 + \frac{1}{2} \alpha_k^2 \mathbb{E}\|\hat{\mathbf{g}}_k\|^2 - \frac{1}{2} \mathbb{E}\|\mathbf{x}_{k+1} - \mathbf{x}_{\text{opt}}\|^2.\end{aligned}$$

- Возьмём ожидание от левой части и просуммируем:

$$\begin{aligned} \sum_{i=0}^k \alpha_i (\mathbb{E} F(\mathbf{x}_i) - F(\mathbf{x}_{\text{opt}})) &\leq \\ &\leq \frac{1}{2} \|\mathbf{x}_0 - \mathbf{x}_{\text{opt}}\|^2 + \frac{1}{2} \sum_{i=0}^k \alpha_i^2 \mathbb{E} \|\hat{\mathbf{g}}_i\|^2 - \frac{1}{2} \mathbb{E} \|\mathbf{x}_{k+1} - \mathbf{x}_{\text{opt}}\|^2 \leq \\ &\leq \frac{1}{2} \|\mathbf{x}_0 - \mathbf{x}_{\text{opt}}\|^2 + \frac{1}{2} \sum_{i=0}^k \alpha_i^2 \mathbb{E} \|\hat{\mathbf{g}}_i\|^2. \end{aligned}$$

- Получилась сумма значений функции в разных точках с весами α_i . Что делать?

- Воспользуемся выпуклостью:

$$\begin{aligned} & \mathbb{E} F \left(\frac{\sum_i \alpha_i \mathbf{x}_i}{\sum_i \alpha_i} \right) - F(\mathbf{x}_{\text{opt}}) \leq \\ & \leq \frac{\sum_i \alpha_i (\mathbb{E} F(\mathbf{x}_i) - F(\mathbf{x}_{\text{opt}}))}{\sum_i \alpha_i} \leq \frac{\frac{1}{2} \|\mathbf{x}_0 - \mathbf{x}_{\text{opt}}\|^2 + \frac{1}{2} \sum_{i=0}^k \alpha_i^2 \mathbb{E} \|\hat{\mathbf{g}}_i\|^2}{\sum_i \alpha_i}. \end{aligned}$$

- Т.е. оценка получилась на значение в линейной комбинации точек (поэтому в статьях часто берут среднее/ожидание или линейную комбинацию, а на практике нет разницы или лучше брать последнюю точку)
- Если $\|\mathbf{x}_0 - \mathbf{x}_{\text{opt}}\| \leq R$ и $\mathbb{E} \|\hat{\mathbf{g}}_k\|^2 \leq G^2$, то

$$\mathbb{E} F(\hat{\mathbf{x}}_k) - F(\mathbf{x}_{\text{opt}}) \leq \frac{R^2 + G^2 \sum_{i=0}^k \alpha_i^2}{2 \sum_{i=0}^k \alpha_i}.$$

- Это самая главная оценка про SGD:


$$\mathbb{E}F(\hat{\mathbf{x}}_k) - F(\mathbf{x}_{\text{opt}}) \leq \frac{R^2 + G^2 \sum_{i=0}^k \alpha_i^2}{2 \sum_{i=0}^k \alpha_i}.$$

- R – оценка начальной невязки, а G – оценка чего-то вроде дисперсии стохастического градиента.
- Например, для постоянного шага $\alpha_i = h$

$$\mathbb{E}F(\hat{\mathbf{x}}_k) - F(\mathbf{x}_{\text{opt}}) \leq \frac{R^2}{2h(k+1)} + \frac{G^2 h}{2} \xrightarrow{k \rightarrow \infty} \frac{G^2 h}{2}.$$

- Итоги про SGD:
 - SGD приходит в «регион неопределённости» радиуса $\frac{1}{2}G^2h$, и этот радиус пропорционален длине шага;
 - чем быстрее идём, тем быстрее придём, но регион неопределённости будет больше, т.е. по идее надо уменьшать со временем скорость обучения;
 - SGD сходится медленно: полный GD для выпуклых функций сходится за $O(1/k)$, а SGD – за $O(1/\sqrt{k})$;
 - но далеко от региона неопределённости у нас скорость тоже $O(1/k)$ получилась для постоянной скорости обучения, т.е. замедляется только уже близко к оптимуму, и вообще цель наша – достичь региона неопределённости;
 - но всё равно всё зависит от G , и это будет особенно важно потом в нейробайесовских методах.

- Значит, нужны какие-то улучшения. Что-то делать со скоростью обучения.
- Скорость обучения лучше не уменьшать слишком быстро.



- Но это в любом случае никак не учитывает собственно F .

МЕТОД МОМЕНТОВ

- *Метод моментов* (momentum): сохраним часть скорости, как у материальной точки.
- С инерцией получается

$$u_t = \gamma u_{t-1} + \eta \nabla_{\mathbf{x}} F(\mathbf{x}),$$

$$\mathbf{x} = \mathbf{x} - u_t.$$

- И теперь мы сохраняем γu_{t-1} .





without momentum



with momentum

МЕТОД МОМЕНТОВ

- Мы ведь на самом деле уже знаем, что попадём в γu_{t-1} на промежуточном шаге.
- Давайте прямо там, на полпути, и вычислим градиент!




- *Метод Нестерова* (Nesterov's momentum):

$$u_t = \gamma u_{t-1} + \eta \nabla_{\mathbf{x}} F(\mathbf{x} - \gamma u_{t-1})$$



- Всё равно, конечно, проблемы не пропадают:



- Можно ли ещё лучше?..

- Заметим, что до сих пор скорость обучения была одна во всех направлениях, мы пытались выбрать направление как бы глобально.
- Идея: давайте быстрее двигаться по тем параметрам, которые не сильно меняются, и медленнее по быстро меняющимся параметрам.

- *Adagrad*: давайте накапливать историю этой скорости изменений и учитывать её.
- Обозначая $g_{t,i} = \nabla_{\mathbf{w}_i} L(\mathbf{w})$, получим

$$\mathbf{w}_{t+1,i} = \mathbf{w}_{t,i} - \frac{\eta}{\sqrt{G_{t,ii} + \epsilon}} \cdot g_{t,i},$$

где G_t – диагональная матрица с $G_{t,ii} = G_{t-1,ii} + g_{t,i}^2$, которая накапливает общее значение градиента по всей истории обучения.

- Так что скорость обучения всё время уменьшается, но с разной скоростью для разных $\mathbf{w}_i$.

- Проблема: G всё увеличивается и увеличивается, и скорость обучения иногда уменьшается слишком быстро.
- *Adadelta* (Zeiler, 2012) – та же идея, но две новых модификации.
- Во-первых, историю градиентов мы теперь считаем с затуханием:

$$G_{t,ii} = \rho G_{t-1,ii} + (1 - \rho) g_{t,i}^2.$$

- А всё остальное здесь точно так же:

$$\mathbf{u}_t = -\frac{\eta}{\sqrt{G_{t-1} + \epsilon}} \mathbf{g}_{t-1}.$$

- Во-вторых, надо бы «единицы измерения» привести в соответствие.
- В предыдущих методах была проблема:
 - в обычном градиентном спуске или методе моментов «единицы измерения» обновления параметров $\Delta \mathbf{w}$ — это единицы измерения градиента, т.е. если веса в секундах, а целевая функция в метрах, то градиент будет иметь размерность «метр в секунду», и мы вычитаем метры в секунду из секунд;
 - а в Adagrad получалось, что значения обновлений $\Delta \mathbf{w}$ зависели от отношений градиентов, и величина обновлений вовсе безразмерная.

- Эта проблема решается в методе второго порядка: обновление параметров $\Delta \mathbf{w}$ пропорционально $H^{-1} \nabla_{\mathbf{w}} f$, то есть размерность будет

$$\Delta \mathbf{w} \propto H^{-1} \nabla_{\mathbf{w}} f \propto \frac{\frac{\partial f}{\partial \mathbf{w}}}{\frac{\partial^2 f}{\partial \mathbf{w}^2}} \propto \text{размерность } \mathbf{w}.$$

- Чтобы привести *Adadelta* в соответствие, нужно домножить на ещё одно экспоненциальное среднее, но теперь уже от квадратов обновлений параметров, а не от градиента.
- Настоящее среднее мы не знаем, аппроксимируем предыдущими шагами:

$$\mathbb{E} [\Delta \mathbf{w}^2]_t = \rho \mathbb{E} [\Delta \mathbf{w}^2]_{t-1} + (1 - \rho) \Delta \mathbf{w}^2, \text{ где}$$
$$u_t = - \frac{\sqrt{\mathbb{E} [\Delta \mathbf{w}^2]_{t-1} + \epsilon}}{\sqrt{G_{t-1} + \epsilon}} \cdot g_{t-1}.$$

- Следующий вариант – *RMSprop* из курса Хинтона.
- Практически то же, что *Adadelta*, только *RMSprop* не делает вторую поправку с изменением единиц и хранением истории самих обновлений, а просто использует корень из среднего от квадратов (вот он где, RMS) от градиентов:

$$u_t = -\frac{\eta}{\sqrt{G_{t-1} + \epsilon}} \cdot g_{t-1}.$$

- И последний алгоритм – *Adam* (Kingma, Ba, 2014).
- Модификация *Adagrad* со сглаженными версиями среднего и среднеквадратичного градиентов:

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t,$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2,$$

$$u_t = \frac{\eta}{\sqrt{v_t} + \epsilon} m_t.$$



- (Kingma, Ba, 2014) рекомендуют $\beta_1 = 0.9$, $\beta_2 = 0.999$, $\epsilon = 10^{-8}$.
- *Adam* практически не требует настройки, используется на практике очень часто.
- ...[<http://ruder.io/optimizing-gradient-descent/>]...

АДАПТИВНЫЕ МЕТОДЫ ГРАДИЕНТНОГО СПУСКА

- А ещё можно совместить Adam и Нестерова – Nadam (Dozat, 2016)

Algorithm 8 Nesterov-accelerated adaptive moment estimation

$$\begin{aligned} \mathbf{g}_t &\leftarrow \nabla_{\theta_{t-1}} f(\theta_{t-1}) \\ \hat{\mathbf{g}} &\leftarrow \frac{\mathbf{g}_t}{1 - \prod_{i=1}^t \mu_i} \\ \mathbf{m}_t &\leftarrow \mu \mathbf{m}_{t-1} + (1 - \mu) \mathbf{g}_t \\ \hat{\mathbf{m}}_t &\leftarrow \frac{\mathbf{m}_t}{1 - \prod_{i=1}^{t+1} \mu_i} \\ \mathbf{n}_t &\leftarrow \nu \mathbf{n}_{t-1} + (1 - \nu) \mathbf{g}_t^2 \\ \hat{\mathbf{n}}_t &\leftarrow \frac{\mathbf{n}_t}{1 - \prod_{i=1}^t \nu_i} \\ \tilde{\mathbf{m}}_t &\leftarrow (1 - \mu_t) \hat{\mathbf{g}}_t + \mu_{t+1} \hat{\mathbf{m}}_t \\ \theta_t &\leftarrow \theta_{t-1} - \eta \frac{\tilde{\mathbf{m}}_t}{\sqrt{\hat{\mathbf{n}}_t} + \epsilon} \end{aligned}$$



- Чуть более общий взгляд – всё это выглядит вот так:

- обычный стохастический градиентный спуск:

$$\mathbf{w}_{k+1} = \mathbf{w}_k - \alpha_k \tilde{\nabla} f(\mathbf{w}_k), \text{ где } \tilde{\nabla} f(\mathbf{w}_k) = \nabla f(\mathbf{w}_k; \mathbf{x}_{i_k});$$

- SGD с моментами:

$$\mathbf{w}_{k+1} = \mathbf{w}_k - \alpha_k \tilde{\nabla} f(\mathbf{w}_k + \gamma_k (\mathbf{w}_k - \mathbf{w}_{k-1})) + \beta_k (\mathbf{w}_k - \mathbf{w}_{k-1});$$

- адаптивный SGD:


$$\mathbf{w}_{k+1} = \mathbf{w}_k - \alpha_k H_k^{-1} \tilde{\nabla} f(\mathbf{w}_k + \gamma_k (\mathbf{w}_k - \mathbf{w}_{k-1})) + \beta_k H_k^{-1} H_{k-1} (\mathbf{w}_k - \mathbf{w}_{k-1}),$$

где обычно $H_k = \text{diag} \left(\left[\sum_{i=1}^k \eta_i \mathbf{g}_i \circ \mathbf{g}_i \right]^{1/2} \right)$, где

$\mathbf{g}_k = \tilde{\nabla} f(\mathbf{w}_k + \gamma_k (\mathbf{w}_k - \mathbf{w}_{k-1}))$ (т.е. H_k – это диагональная матрица, элементы которой – квадратные корни из линейных комбинаций квадратов предыдущих градиентов).

- Т.е. адаптивные методы пытаются подстроиться под геометрию в пространстве данных, а SGD и его варианты используют базовую L_2 -геометрию с $H_k = \mathbf{I}$.

- Когда Adam появился, все были очень счастливы, и было отчего:





- Но потом выяснилось, что не всё так просто... часто применяли простой SGD. Почему?

- The Marginal Value of Adaptive Gradient Methods in Machine Learning (Wilson et al., May 2017)
- Основные выводы:
 - когда в задаче несколько глобальных минимумов, разные алгоритмы могут найти совершенно разные решения из одной и той же начальной точки;
 - в частности, адаптивные методы могут приходить к оверфиттингу, т.е. не-обобщающимся локальным решениям;
 - и это *не только теоретический худший случай, но и практика.*

ADAM, ADAMW И ДРУГИЕ ЖИВОТНЫЕ

- The Marginal Value of Adaptive Gradient Methods in Machine Learning (Wilson et al., May 2017)




(a) War and Peace (Training Set)


(b) War and Peace (Test Set)

ADAM, ADAMW и ДРУГИЕ ЖИВОТНЫЕ


- Но Adam всё равно гораздо быстрее начинает, конечно.
- Поэтому предлагали, например, переключаться с Adam на SGD в нужное время (Keskar, Socher, Dec 2017)




(e) ResNet-32 — CIFAR-100



(f) DenseNet — CIFAR-100



(g) PyramidNet — CIFAR-100



(h) SENet — CIFAR-100

- Всё равно, конечно, SGD не получилось превзойти, и даже не всегда наравне.
- Но и это ещё не вся история...

- Fixing Weight Decay Regularization in Adam (Loshchilov, Hutter, Feb 2018):
 - я мельком говорил, что weight decay – это то же самое, что L_2 -регуляризация;
 - но для адаптивных методов это, оказывается, не совсем так...
 - давайте разберёмся, что такое weight decay и почему это может быть не эквивалентно.

- Исходный weight decay (Hanson, Pratt, 1988):

$$\mathbf{x}_{t+1} = (1 - w)\mathbf{x}_t - \eta \nabla f_t(\mathbf{x}_t),$$

где w – это скорость weight decay, η – скорость обучения.

- Там же сразу отмечено, что это эквивалентно тому, чтобы поменять f :

$$f_t^{\text{reg}}(\mathbf{x}_t) = f_t(\mathbf{x}_t) + \frac{w}{2} \|\mathbf{x}_t\|_2^2.$$

- А можно и просто градиент подправить:

$$\nabla f_t^{\text{reg}}(\mathbf{x}_t) = \nabla f_t(\mathbf{x}_t) + w\mathbf{x}_t.$$

- Это всё, конечно, верно, но...

- ...но не работает уже даже просто с моментами:

Algorithm 1 **SGD with L_2 regularization** and
SGD with weight decay (SGDW), both with momentum

- 1: **given** initial learning rate $\alpha \in \mathbb{R}$, momentum factor $\beta_1 \in \mathbb{R}$, weight decay / L_2 regularization factor $w \in \mathbb{R}$
- 2: **initialize** time step $t \leftarrow 0$, parameter vector $\mathbf{x}_{t=0} \in \mathbb{R}^n$, first moment vector $\mathbf{m}_{t=0} \leftarrow \mathbf{0}$, schedule multiplier $\eta_{t=0} \in \mathbb{R}$
- 3: **repeat**
- 4: $t \leftarrow t + 1$
- 5: $\nabla f_t(\mathbf{x}_{t-1}) \leftarrow \text{SelectBatch}(\mathbf{x}_{t-1})$ $\triangleright$ select batch and return the corresponding gradient
- 6: $\mathbf{g}_t \leftarrow \nabla f_t(\mathbf{x}_{t-1}) + w\mathbf{x}_{t-1}$
- 7: $\eta_t \leftarrow \text{SetScheduleMultiplier}(t)$ $\triangleright$ can be fixed, decay, be used for warm restarts
- 8: $\mathbf{m}_t \leftarrow \beta_1\mathbf{m}_{t-1} + \eta_t\alpha\mathbf{g}_t$
- 9: $\mathbf{x}_t \leftarrow \mathbf{x}_{t-1} - \mathbf{m}_t - \eta_t w\mathbf{x}_{t-1}$
- 10: **until** stopping criterion is met
- 11: **return** optimized parameters $\mathbf{x}_t$

- Получается, что $\mathbf{x}_t$ затухает на $\alpha w\mathbf{x}_{t-1}$, а не на $w\mathbf{x}_{t-1}$; чтобы восстановить поведение, надо взять $w_t = \frac{\alpha}{\alpha'}\delta$, и теперь выбор гиперпараметров α и w завязан друг на друга.
- Решение – просто перенести decay в само изменение $\mathbf{x}_t$ (строка 9) и добавить масштабирование η_t .


- То же самое происходит и с Adam:

Algorithm	2	Adam with L_2 regularization	and
Adam with weight decay (AdamW)			
1: given $\alpha = 0.001, \beta_1 = 0.9, \beta_2 = 0.999, \epsilon = 10^{-8}, w \in \mathbb{R}$ 2: initialize time step $t \leftarrow 0$, parameter vector $\mathbf{x}_{t=0} \in \mathbb{R}^n$, first moment vector $\mathbf{m}_{t=0} \leftarrow \mathbf{0}$, second moment vector $\mathbf{v}_{t=0} \leftarrow \mathbf{0}$, schedule multiplier $\eta_{t=0} \in \mathbb{R}$ 3: repeat 4: $t \leftarrow t + 1$ 5: $\nabla f_t(\mathbf{x}_{t-1}) \leftarrow \text{SelectBatch}(\mathbf{x}_{t-1})$ $\triangleright$ select batch and return the corresponding gradient 6: $\mathbf{g}_t \leftarrow \nabla f_t(\mathbf{x}_{t-1}) + w\mathbf{x}_{t-1}$ 7: $\mathbf{m}_t \leftarrow \beta_1\mathbf{m}_{t-1} + (1 - \beta_1)\mathbf{g}_t$ $\triangleright$ here and below all operations are element-wise 8: $\mathbf{v}_t \leftarrow \beta_2\mathbf{v}_{t-1} + (1 - \beta_2)\mathbf{g}_t^2$ 9: $\hat{\mathbf{m}}_t \leftarrow \mathbf{m}_t / (1 - \beta_1^t)$ $\triangleright \beta_1$ is taken to the power of t 10: $\hat{\mathbf{v}}_t \leftarrow \mathbf{v}_t / (1 - \beta_2^t)$ $\triangleright \beta_2$ is taken to the power of t 11: $\eta_t \leftarrow \text{SetScheduleMultiplier}(t)$ $\triangleright$ can be fixed, decay, or also be used for warm restarts 12: $\mathbf{x}_t \leftarrow \mathbf{x}_{t-1} - \eta_t \left(\alpha \hat{\mathbf{m}}_t / (\sqrt{\hat{\mathbf{v}}_t} + \epsilon) + w\mathbf{x}_{t-1} \right)$ 13: until stopping criterion is met 14: return optimized parameters $\mathbf{x}_t$			

- В базовом Adam веса с большими градиентами меньше затухают, что не всегда хорошо; AdamW восстанавливает исходное поведение.


ADAM, ADAMW и ДРУГИЕ ЖИВОТНЫЕ

- И теперь гиперпараметры разделяются лучше:




ADAM, ADAMW И ДРУГИЕ ЖИВОТНЫЕ

- Да и обобщается лучше:



SUPER-CONVERGENCE И AMSGRAD

- И ещё две мысли. Первая – Super-Convergence (Smith, Topin, Aug 2017)
- Идея в том, чтобы менять скорость обучения циклически –
- Это по сути смесь curriculum learning (Bengio et al., 2009) и классического simulated annealing.



- Но вроде бы это не воспроизводится устойчиво.

- Другая идея с похожей судьбой – amsgrad (Reddi et al., Mar 2018), ICLR 2018 best paper! Идея:
 - экспоненциальное среднее в Adam/RMSprop может привести к не-сходимости;
 - в частности, в доказательстве сходимости Adam есть ошибка;
 - а AMSGrad хранит максимальный размер градиента, и это типа лучше.

Algorithm 2 AMSGRAD

Input: $x_1 \in \mathcal{F}$, step size $\{\alpha_t\}_{t=1}^T$, $\{\beta_{1t}\}_{t=1}^T$, β_2
Set $m_0 = 0$, $v_0 = 0$ and $\hat{v}_0 = 0$
for $t = 1$ **to** T **do**
 $g_t = \nabla f_t(x_t)$
 $m_t = \beta_{1t}m_{t-1} + (1 - \beta_{1t})g_t$
 $v_t = \beta_2v_{t-1} + (1 - \beta_2)g_t^2$
 $\hat{v}_t = \max(\hat{v}_{t-1}, v_t)$ and $\hat{V}_t = \text{diag}(\hat{v}_t)$
 $x_{t+1} = \Pi_{\mathcal{F}, \sqrt{\hat{V}_t}}(x_t - \alpha_t m_t / \sqrt{\hat{v}_t})$
end for

- Но это тоже совсем не подтверждается на практике...


РЕГУЛЯРИЗАЦИЯ В НЕЙРОННЫХ СЕТЯХ

- У нейронных сетей *очень* много параметров.
- Регуляризация совершенно необходима.
- L_2 или L_1 регуляризация ($\lambda \sum_w w^2$ или $\lambda \sum_w |w|$) — это классический метод и в нейронных сетях, *weight decay*.
- Очень легко добавить: ещё одно слагаемое в целевую функцию, и иногда всё ещё полезно.

- Регуляризация есть во всех библиотеках. Например, в *Keras*:
 - `W_regularizer` добавит регуляризатор на матрицу весов слоя;
 - `b_regularizer` — на вектор свободных членов;
 - `activity_regularizer` — на вектор выходов.

РЕГУЛЯРИЗАЦИЯ В НЕЙРОННЫХ СЕТЯХ

- Второй способ регуляризации: *ранняя остановка* (early stopping).
- Давайте просто останавливаться, когда начнёт ухудшаться ошибка на валидационном множестве!
- Тоже есть из коробки в *Keras*, через callbacks.




- Третий способ – max-norm constraint.
- Давайте искусственно ограничим норму вектора весов каждого нейрона:


$$\|\mathbf{w}\|^2 \leq c.$$

- Это можно делать в процессе оптимизации: когда $\mathbf{w}$ выходит за шар радиуса c , проецируем его обратно.


- Но есть и другие варианты.
- *Дропаут* (dropout): давайте просто выбросим некоторые нейроны случайным образом с вероятностью p !
(Srivastava et al., 2014)



- Получается, что мы сэмплируем кучу сетей, и нейрон получает на вход «среднюю» активацию от разных архитектур.
- Технический вопрос: как потом применять? Неужели надо опять сэмплировать кучу архитектур и усреднять?




- Чтобы применить обученную сеть, умножим результат на $1/p$, сохраняя ожидание выхода!




- В качестве вероятности часто можно брать просто $p = \frac{1}{2}$, большой разницы нет.


- Dropout улучшает (большие и свёрточные) нейронные сети *очень заметно*... но почему? WTF?



- Идея 1: нейроны теперь должны обучать признаки самостоятельно, а не рассчитывать на других.




(a) Without dropout




(b) Dropout with $p = 0.5$.

- Аналогично, и разреженность появляется.



(a) Without dropout



(b) Dropout with $p = 0.5$.

- Идея 2: мы как бы усредняем огромное число (2^N) сетей с общими весами, каждую обучая на один шаг.
- Усреднять кучу моделей очень полезно – bootstrapping/xgboost/всё такое...



- Получается, что дропаут – это такой экстремальный бутстреппинг.

- Идея 3: this is just like sex!
- Как работает половое размножение?
- Важно собрать не просто хорошую комбинацию, а *устойчивую* хорошую комбинацию.

BY ADI LIVNAT AND CHRISTOS PAPADIMITRIOU

Sex as an Algorithm

- Идея 4: нейрон посылает активацию a с вероятностью 0.5.
- Но можно наоборот: давайте посылать 0.5 (или 1) с вероятностью a .
- Ожидание то же, дисперсия для маленьких p растёт (что неплохо).
- И у нас получаются стохастические нейроны, которые посылают сигналы случайно – точно как в мозге!
- Улучшение примерно то же, как от dropout, но нужно меньше коммуникации между нейронами (один бит вместо float).
- Т.е. стохастические нейроны в мозге работают как дропаут-регуляризатор!
- Возможно, именно поэтому мы умеем задумываться.

- Идея 5: dropout — это специальная форма априорного распределения.
- Это очень полезный взгляд, с ним победили dropout в рекуррентных сетях.
- Но для этого нужно сначала поговорить о нейронных сетях по-байесовски...
- Вернёмся к этому, если будет время.

- Итого получается, что dropout – это очень крутой метод.



- Но и он сейчас отходит на второй план из-за нормализации по мини-батчам и новых версий градиентного спуска.
- О них чуть позже, а сначала об инициализации весов.

СПАСИБО!

Спасибо за внимание!

