

# Искусственные нейронные сети: градиентные методы оптимизации

К. В. Воронцов  
[vokov@forecsys.ru](mailto:vokov@forecsys.ru)

Этот курс доступен на странице вики-ресурса  
<http://www.MachineLearning.ru/wiki>  
«Машинное обучение (курс лекций, К.В.Воронцов)»

11 сентября 2018 • ШАД Яндекс

## 1 Многослойные нейронные сети

- Проблема полноты
- Вычислительные возможности нейронных сетей
- Многослойная нейронная сеть

## 2 Метод обратного распространения ошибок

- Метод стохастического градиента
- Алгоритм BackProp
- BackProp: преимущества и недостатки

## 3 Эвристики

- Эвристики для улучшения сходимости
- Методы регуляризации
- Функции активации и другие эвристики

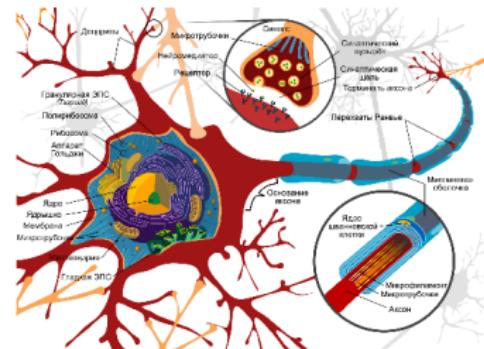
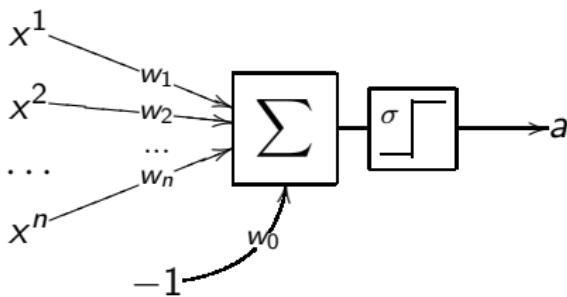
# Напоминание: линейная модель нейрона МакКаллока-Питтса

$f_j: X \rightarrow \mathbb{R}$ ,  $j = 1, \dots, n$  — числовые признаки;

$$a(x, w) = \sigma(\langle w, x \rangle) = \sigma\left(\sum_{j=1}^n w_j f_j(x) - w_0\right),$$

где  $w_0, w_1, \dots, w_n \in \mathbb{R}$  — веса признаков;

$\sigma(z)$  — функция активации, например,  $\text{sign}(z)$ ,  $\frac{1}{1+e^{-z}}$ ,  $(z)_+$



## Линейные методы классификации и регрессии

Обучающая выборка:  $X^\ell = (x_i, y_i)_{i=1}^\ell$ , объекты  $x_i \in \mathbb{R}^n$ , ответы  $y_i$

**Задача классификации:**  $Y = \{\pm 1\}$ ,  $a(x, w) = \text{sign}\langle w, x_i \rangle$ ;

$\mathcal{L}(M)$  — невозрастающая функция отступа, например,

$\mathcal{L}(M) = \ln(1 + e^{-M})$ ,  $(1 - M)_+$ ,  $e^{-M}$ ,  $\frac{1}{1+e^{-M}}$ , и др.

$$Q(w; X^\ell) = \sum_{i=1}^{\ell} \mathcal{L}\left(\underbrace{\langle w, x_i \rangle}_{M_i(w)} y_i\right) \rightarrow \min_w;$$

**Задача регрессии:**  $Y = \mathbb{R}$ ,  $a(x, w) = \sigma(\langle w, x_i \rangle)$ ;

$$Q(w; X^\ell) = \sum_{i=1}^{\ell} (\sigma(\langle w, x_i \rangle) - y_i)^2 \rightarrow \min_w;$$

**Насколько богатый класс функций реализуется нейроном?  
А сетью (суперпозицией) нейронов?**

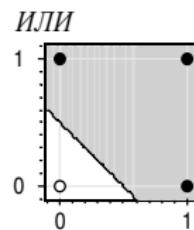
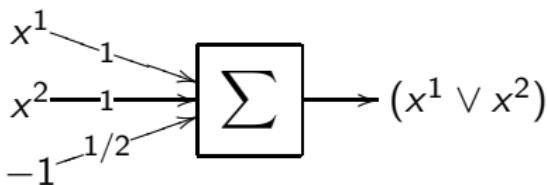
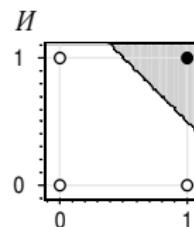
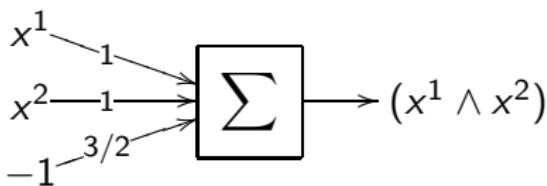
# Нейронная реализация логических функций

Функции И, ИЛИ, НЕ от бинарных переменных  $x^1$  и  $x^2$ :

$$x^1 \wedge x^2 = [x^1 + x^2 - \frac{3}{2} > 0];$$

$$x^1 \vee x^2 = [x^1 + x^2 - \frac{1}{2} > 0];$$

$$\neg x^1 = [-x^1 + \frac{1}{2} > 0];$$



## Логическая функция XOR (исключающее ИЛИ)

Функция  $x^1 \oplus x^2 = [x^1 \neq x^2]$  не реализуема одним нейроном.

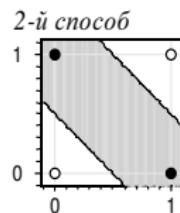
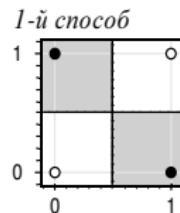
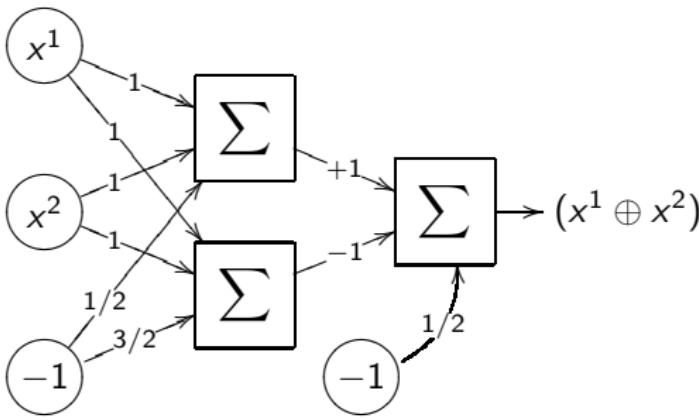
Два способа реализации:

- Добавлением нелинейного признака:

$$x^1 \oplus x^2 = [x^1 + x^2 - 2x^1x^2 - \frac{1}{2} > 0];$$

- Сетью (двухслойной суперпозицией) функций И, ИЛИ, НЕ:

$$x^1 \oplus x^2 = [(x^1 \vee x^2) - (x^1 \wedge x^2) - \frac{1}{2} > 0].$$



# Любую ли функцию можно представить нейросетью?

- Двухслойная сеть в  $\{0, 1\}^n$  позволяет реализовать произвольную булеву функцию (ДНФ).
- Двухслойная сеть в  $\mathbb{R}^n$  позволяет отделить произвольный выпуклый многогранник.
- Трёхслойная сеть  $\mathbb{R}^n$  позволяет отделить произвольную многогранную область, не обязательно выпуклую, и даже не обязательно связную.
- С помощью линейных операций и одной нелинейной функции активации  $\sigma$  можно приблизить любую непрерывную функцию с любой желаемой точностью.

## Практические рекомендации:

- Двух-трёх слоёв теоретически достаточно.
- Глубокие сети — это встроенное обучение признаков.

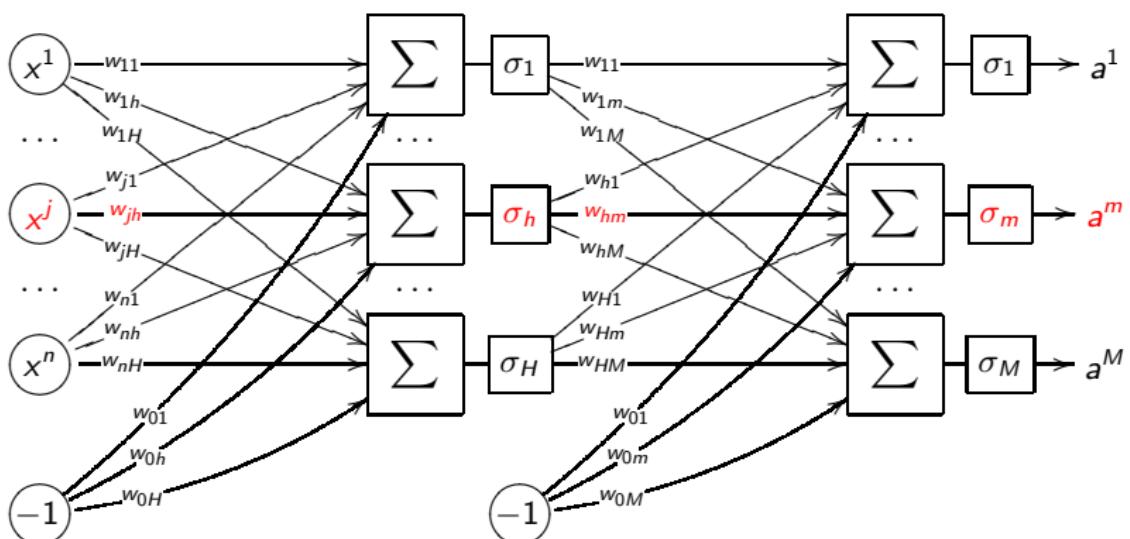
## Двухслойная нейронная сеть

Пусть для общности  $Y = \mathbb{R}^M$ , для простоты слоёв только два.

входной слой,  
 $n$  признаков

скрытый слой,  
 $H$  нейронов

выходной слой,  
 $M$  нейронов



Вектор параметров модели  $w \equiv (w_{jh}, w_{hm}) \in \mathbb{R}^{Hn+H+MH+M}$ .

## Напоминание: Алгоритм SG (Stochastic Gradient)

Минимизация средних потерь на обучающей выборке:

$$Q(w) := \frac{1}{\ell} \sum_{i=1}^{\ell} \mathcal{L}_i(w) \rightarrow \min_w .$$

**Вход:** выборка  $X^\ell$ ; темп обучения  $\eta$ ; параметр  $\lambda$ ;

**Выход:** вектор весов  $w \equiv (w_{jh}, w_{hm})$ ;

- 1: инициализировать веса  $w$  и текущую оценку  $Q(w)$ ;
- 2: **повторять**
- 3: выбрать объект  $x_i$  из  $X^\ell$  (например, случайно);
- 4: вычислить потерю  $\mathcal{L}_i := \mathcal{L}_i(w)$ ;
- 5: градиентный шаг:  $w := w - \eta \mathcal{L}'_i(w)$ ;
- 6: оценить значение функционала:  $Q := (1 - \lambda)Q + \lambda \mathcal{L}_i$ ;
- 7: **пока** значение  $Q$  и/или веса  $w$  не стабилизируются;

## Задача дифференцирования суперпозиции функций

Выходные значения сети  $a^m(x_i)$ ,  $m = 1..M$  на объекте  $x_i$ :

$$a^m(x_i) = \sigma_m \left( \sum_{h=0}^H w_{hm} u^h(x_i) \right); \quad u^h(x_i) = \sigma_h \left( \sum_{j=0}^J w_{jh} f_j(x_i) \right).$$

Без ограничения общности (только для примера) будем рассматривать среднеквадратичную функцию потерь:

$$\mathcal{L}_i(w) = \frac{1}{2} \sum_{m=1}^M (a^m(x_i) - y_i^m)^2.$$

**Промежуточная задача:** найти частные производные

$$\frac{\partial \mathcal{L}_i(w)}{\partial a^m}; \quad \frac{\partial \mathcal{L}_i(w)}{\partial u^h}.$$

## Быстрое вычисление градиента

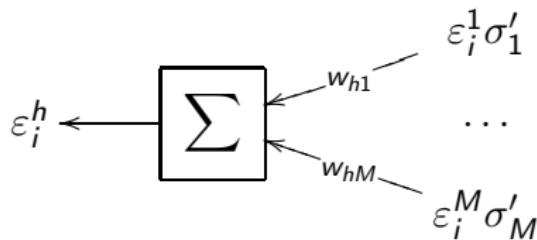
**Промежуточная задача:** частные производные

$$\frac{\partial \mathcal{L}_i(w)}{\partial a^m} = a^m(x_i) - y_i^m = \varepsilon_i^m$$

— это ошибка на выходном слое (для квадратичных потерь);

$$\frac{\partial \mathcal{L}_i(w)}{\partial u^h} = \sum_{m=1}^M \frac{\partial \mathcal{L}_i(w)}{\partial a^m} \sigma'_m(\cdot) w_{hm} = \sum_{m=1}^M \varepsilon_i^m \sigma'_m w_{hm} = \varepsilon_i^h$$

— назовём это *ошибкой на скрытом слое*. Похоже, что  $\varepsilon_i^h$  вычисляется по  $\varepsilon_i^m$ , если запустить сеть «задом наперёд»:



## Быстрое вычисление градиента

Теперь, имея частные производные  $\mathcal{L}_i(w)$  по  $a^m$  и  $u^h$ ,  
легко выписать градиент  $\mathcal{L}_i(w)$  по весам  $w$ :

$$\frac{\partial \mathcal{L}_i(w)}{\partial w_{hm}} = \frac{\partial \mathcal{L}_i(w)}{\partial a^m} \frac{\partial a^m}{\partial w_{hm}} = \varepsilon_i^m \sigma'_m u^h(x_i), \quad m = 1..M, \quad h = 0..H;$$

$$\frac{\partial \mathcal{L}_i(w)}{\partial w_{jh}} = \frac{\partial \mathcal{L}_i(w)}{\partial u^h} \frac{\partial u^h}{\partial w_{jh}} = \varepsilon_i^h \sigma'_h f_j(x_i), \quad h = 1..H, \quad j = 0..n;$$

**Алгоритм обратного распространения ошибки BackProp:**

**Вход:**  $X^\ell = (x_i, y_i)_{i=1}^\ell \subset \mathbb{R}^n \times \mathbb{R}^M$ ; параметры  $H, \lambda, \eta$ ;

**Выход:** синаптические веса  $w_{jh}, w_{hm}$ ;

---

1: ...

# Алгоритм BackProp

1: инициализировать веса  $w_{jh}, w_{hm}$ ;

2: **повторять**

3: выбрать объект  $x_i$  из  $X^\ell$  (например, случайно);

4: прямой ход:

$$u_i^h := \sigma_h\left(\sum_{j=0}^J w_{jh} x_i^j\right), \quad h = 1..H;$$

$$a_i^m := \sigma_m\left(\sum_{h=0}^H w_{hm} u_i^h\right), \quad m = 1..M;$$

$$\varepsilon_i^m := \frac{\partial \mathcal{L}_i(w)}{\partial a^m}, \quad m = 1..M;$$

5:  $Q := (1 - \lambda)Q + \lambda \mathcal{L}_i(w)$ ;

6: обратный ход:

$$\varepsilon_i^h := \sum_{m=1}^M \varepsilon_i^m \sigma'_m w_{hm}, \quad h = 1..H;$$

7: градиентный шаг:

$$w_{hm} := w_{hm} - \eta \varepsilon_i^m \sigma'_m u_i^h, \quad h = 0..H, \quad m = 1..M;$$

$$w_{jh} := w_{jh} - \eta \varepsilon_i^h \sigma'_h x_i^j, \quad j = 0..n, \quad h = 1..H;$$

8: **пока**  $Q$  не стабилизируется;

## Алгоритм BackProp: преимущества и недостатки

### Преимущества:

- быстрое вычисление градиента
- обобщение на любые  $\sigma$ ,  $\mathcal{L}$  и любое число слоёв
- возможность динамического (потокового) обучения
- сублинейное обучение на сверхбольших выборках  
(когда части объектов  $x_i$  уже достаточно для обучения)
- возможно распараллеливание

### Недостатки — все те же, свойственные SG:

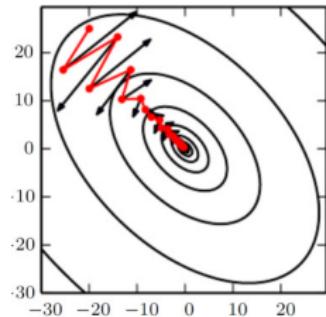
- медленная сходимость
- застревание в локальных экстремумах
- «паралич сети» из-за горизонтальных асимптот  $\sigma$
- проблема переобучения
- подбор комплекса эвристик является искусством

## Метод накопления импульса (momentum)

**Momentum** — экспоненциальное скользящее среднее градиента по  $\approx \frac{1}{1-\gamma}$  последним итерациям [Б.Т.Поляк, 1964]:

$$v := \gamma v + \eta \mathcal{L}'_i(w)$$

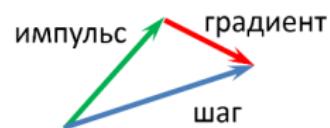
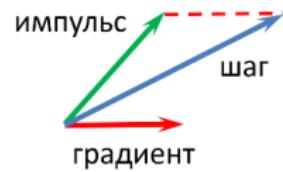
$$w := w - v$$



**NAG** (Nesterov's accelerated gradient) — стохастический градиент с импульсом Нестерова [1983]:

$$v := \gamma v + \eta \mathcal{L}'_i(w - \gamma v)$$

$$w := w - v$$



## Адаптивные градиенты

**RMSProp** (*running mean square*) — адаптация скорости изменения весов, скользящим средним по  $\approx \frac{1}{1-\alpha}$  итерациям:

$$G := \alpha G + (1 - \alpha) \mathcal{L}'_i(w) \odot \mathcal{L}'_i(w)$$
$$w := w - \eta \mathcal{L}'_i(w) \oslash (\sqrt{G} + \varepsilon)$$

где  $\odot$  и  $\oslash$  — покординатное умножение и деление векторов.

**AdaDelta** (*adaptive learning rate*) — двойная нормировка приращений весов, после которой можно брать  $\eta = 1$ :

$$G := \alpha G + (1 - \alpha) \mathcal{L}'_i(w) \odot \mathcal{L}'_i(w)$$
$$\delta := \mathcal{L}'_i(w) \odot \frac{\sqrt{\Delta} + \varepsilon}{\sqrt{G} + \varepsilon}$$
$$\Delta := \alpha \Delta + (1 - \alpha) \delta \odot \delta$$
$$w := w - \eta \delta$$

## Комбинированные градиентные методы

**Adam** (adaptive momentum) = импульс + RMSProp:

$$\begin{aligned} v &:= \gamma v + (1 - \gamma) \mathcal{L}'_i(w) & \hat{v} &:= v(1 - \gamma^k)^{-1} \\ G &:= \alpha G + (1 - \alpha) \mathcal{L}'_i(w) \odot \mathcal{L}'_i(w) & \hat{G} &:= G(1 - \alpha^k)^{-1} \\ w &:= w - \eta \hat{v} \oslash (\sqrt{\hat{G}} + \varepsilon) \end{aligned}$$

Калибровка  $\hat{v}$ ,  $\hat{G}$  увеличивает  $v$ ,  $G$  на первых итерациях,  
где  $k$  — номер итерации;  $\gamma = 0.9$ ,  $\alpha = 0.999$ ,  $\varepsilon = 10^{-8}$

**Nadam** (Nesterov-accelerated adaptive momentum):  
те же формулы для  $v$ ,  $\hat{v}$ ,  $G$ ,  $\hat{G}$ ,

$$w := w - \eta \left( \gamma \hat{v} + \frac{1-\gamma}{1-\gamma^k} \mathcal{L}'_i(w) \right) \oslash (\sqrt{\hat{G}} + \varepsilon)$$

---

Timothy Dozat. Incorporating Nesterov Momentum into Adam. ICLR-2016.

## Диагональный метод Левенберга-Марквардта

Метод Ньютона-Рафсона (второго порядка):

$$w := w - \eta (\mathcal{L}_i''(w))^{-1} \mathcal{L}_i'(w),$$

где  $(\mathcal{L}_i''(w)) = \left(\frac{\partial^2 \mathcal{L}_i(w)}{\partial w_{jh} \partial w_{j'h'}}\right)$  — гессиан, размера  $(H(n+M+1)+M)^2$ .

**Эвристика.** Считаем, что гессиан диагонален:

$$w_{jh} := w_{jh} - \eta \left( \frac{\partial^2 \mathcal{L}_i(w)}{\partial w_{jh}^2} + \mu \right)^{-1} \frac{\partial \mathcal{L}_i(w)}{\partial w_{jh}},$$

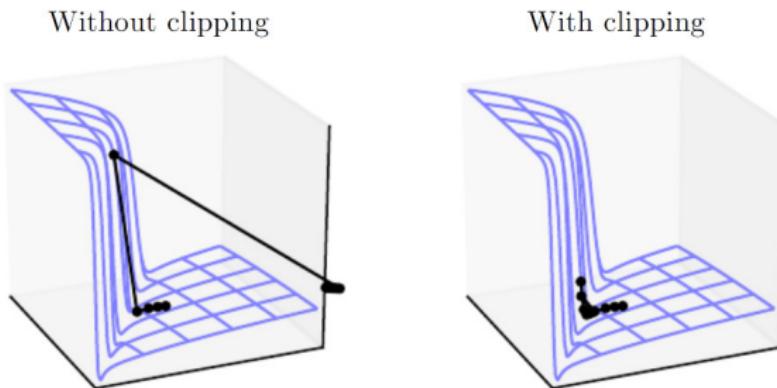
$\eta$  — темп обучения (можно брать  $\eta = 1$ ),

$\mu$  — параметр, предотвращающий обнуление знаменателя.

Отношение  $\eta/\mu$  есть темп обучения на ровных участках функционала  $\mathcal{L}_i(w)$ , где вторая производная обнуляется.

# Проблема взрыва градиента и эвристика gradient clipping

Проблема взрыва градиента (gradient exploding)

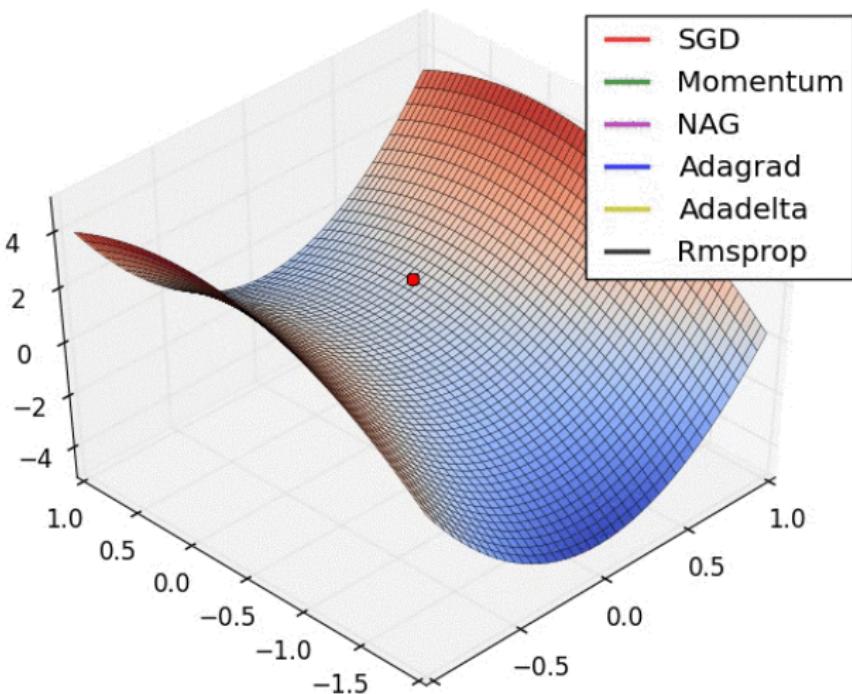


Эвристика Gradient Clipping:

$$\text{если } \|g\| > \theta \text{ то } g := g\theta/\|g\|$$

При грамотном подборе  $\gamma$  проблема взрыва градиента не возникает, и эвристика Gradient Clipping не нужна.

## Сравнение сходимости методов



Alec Radford's animation: <http://cs231n.github.io/assets/nn3/opt1.gif>

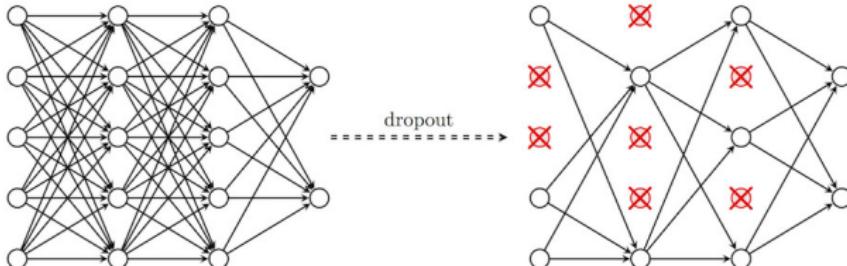
## Метод случайных отключений нейронов (Dropout)

**Этап обучения:** делая градиентный шаг  $\mathcal{L}_i(w) \rightarrow \min_w$ ,  
отключаем  $h$ -ый нейрон  $\ell$ -го слоя с вероятностью  $p_\ell$ :

$$x_{ih}^{\ell+1} = \xi_h^\ell \sigma_h \left( \sum_j w_{jh} x_{ij}^\ell \right), \quad P(\xi_h^\ell = 0) = p_\ell$$

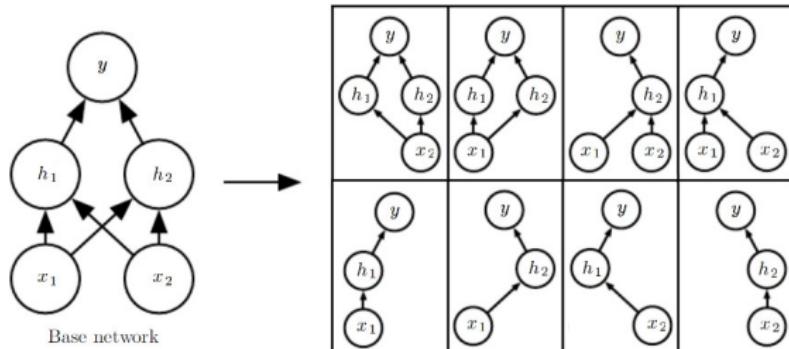
**Этап применения:** включаем все нейроны, но с поправкой:

$$x_{ih}^{\ell+1} = (1 - p_\ell) \sigma_h \left( \sum_j w_{jh} x_{ij}^\ell \right)$$



# Интерпретации Dropout

- ❶ аппроксимируем простое голосование по  $2^N$  сетям с общим набором из  $N$  весов, но с различной архитектурой связей
- ❷ регуляризация: из всех сетей выбираем более устойчивую к утрате  $pN$  нейронов, моделируя надёжность мозга
- ❸ сокращаем переобучение, заставляя разные части сети решать одну и ту же исходную задачу вместо того, чтобы подстраивать их под компенсацию ошибок друг друга



## Обратный Dropout и $L_2$ -регуляризация

На практике чаще используют не Dropout, а *Inverted Dropout*.

**Этап обучения:**

$$x_{ih}^{\ell+1} = \frac{1}{1-p_\ell} \xi_h^\ell \sigma_h \left( \sum_j w_{jh} x_{ij}^\ell \right), \quad P(\xi_h^\ell = 0) = p_\ell$$

**Этап применения** не требует ни модификаций, ни знания  $p_\ell$ :

$$x_{ih}^{\ell+1} = \sigma_h \left( \sum_j w_{jh} x_{ij}^\ell \right)$$

$L_2$ -регуляризация предотвращает рост параметров на обучении:

$$\mathcal{L}_i(w) + \frac{\lambda}{2} \|w\|^2 \rightarrow \min_w$$

Градиентный шаг с Dropout и  $L_2$ -регуляризацией:

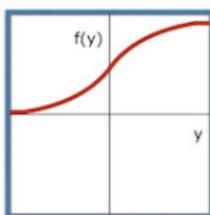
$$w := w(1 - \eta \lambda) - \eta \frac{1}{1-p_\ell} \xi_h^\ell \mathcal{L}'_i(w)$$

## Функции активации ReLU и PReLU (LeakyReLU)

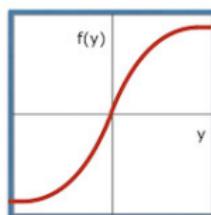
Функции  $\sigma(y) = \frac{1}{1+e^{-y}}$  и  $\text{th}(y) = \frac{e^y - e^{-y}}{e^y + e^{-y}}$  могут приводить к затуханию градиентов или «параличу сети»

Функция положительной срезки (rectified linear unit)

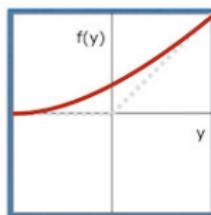
$$\text{ReLU}(y) = \max\{0, y\}; \quad \text{PReLU}(y) = \max\{0, y\} + \alpha \min\{0, y\}$$



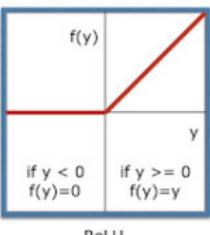
Sigmoid



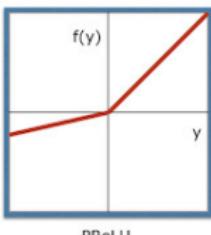
tanh



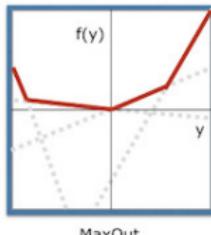
softplus



ReLU



PReLU



MaxOut

## Пакетная нормализация данных (Batch Normalization)

$B = \{x_i\}$  — пакеты (mini-batch) данных.

Усреднение градиентов  $\mathcal{L}_i(w)$  по пакету ускоряет сходимость.

$B^\ell = \{u_i^\ell\}$  — векторы объектов  $x_i$  на выходе  $\ell$ -го слоя.

**Batch Normalization:**

1. Нормировать каждую  $j$ -ю компоненту вектора  $u_i^\ell$  по пакету:

$$\hat{u}_{ij}^\ell = \frac{u_{ij}^\ell - \mu_j}{\sqrt{\sigma_j^2 + \varepsilon}}; \quad \mu_j = \frac{1}{|B|} \sum_{x_i \in B} u_{ij}^\ell; \quad \sigma_j^2 = \frac{1}{|B|} \sum_{x_i \in B} (u_{ij}^\ell - \mu_j)^2.$$

2. Добавить линейный слой с настраиваемыми весами:

$$\tilde{u}_{ij}^\ell = \gamma_j^\ell \hat{u}_{ij}^\ell + \beta_j^\ell$$

3. Параметры  $\gamma_j^\ell$  и  $\beta_j^\ell$  настраиваются BackProp.

## Эвристики для начального приближения

1. Выравнивание дисперсий выходов в разных слоях:

$$w_j := \text{uniform}\left(-\frac{1}{\sqrt{h}}, \frac{1}{\sqrt{h}}\right)$$

2. Выравнивание дисперсий градиентов в разных слоях:

$$w_j := \text{uniform}\left(-\frac{6}{\sqrt{h+m}}, \frac{6}{\sqrt{h+m}}\right),$$

где  $h, m$  — число нейронов в предыдущем и текущем слое

3. Послойное обучение нейронов как линейных моделей:

- либо по случайной подвыборке  $X' \subseteq X^\ell$ ;
- либо по случайному подмножеству входов;
- либо из различных случайных начальных приближений;

тем самым обеспечивается *различность* нейронов.

4. Инициализация весами предобученной модели

5. Инициализация случайным ортогональным базисом

## Прореживание сети (OBD – Optimal Brain Damage)

Пусть  $w$  — локальный минимум  $Q(w)$ , тогда  $Q(w)$  можно аппроксимировать квадратичной формой:

$$Q(w + \delta) = Q(w) + \frac{1}{2} \delta^\top Q''(w) \delta + o(\|\delta\|^2),$$

где  $Q''(w) = \left(\frac{\partial^2 Q(w)}{\partial w_{jh} \partial w_{j'h'}}\right)$  — гессиан, размера  $(H(n+M+1)+M)^2$ .

**Эвристика.** Пусть гессиан  $Q''(w)$  диагонален, тогда

$$\delta^\top Q''(w) \delta = \sum_{j=0}^n \sum_{h=1}^H \delta_{jh}^2 \frac{\partial^2 Q(w)}{\partial w_{jh}^2} + \sum_{h=0}^H \sum_{m=0}^M \delta_{hm}^2 \frac{\partial^2 Q(w)}{\partial w_{hm}^2}.$$

Хотим обнулить вес:  $w_{jh} + \delta_{jh} = 0$ . Как изменится  $Q(w)$ ?

**Определение.** Значимость (salience) веса  $w_{jh}$  — это изменение функционала  $Q(w)$  при его обнулении:  $S_{jh} = w_{jh}^2 \frac{\partial^2 Q(w)}{\partial w_{jh}^2}$ .

## Прореживание сети (OBD – Optimal Brain Damage)

- ➊ В BackProp вычислять вторые производные  $\frac{\partial^2 Q}{\partial w_{jh}^2}$ ,  $\frac{\partial^2 Q}{\partial w_{hm}^2}$ .
- ➋ Если процесс минимизации  $Q(w)$  пришёл в минимум, то
  - ➌ упорядочить все веса по убыванию  $S_{jh}$ ;
  - ➍ удалить  $N$  связей с наименьшей значимостью;
  - ➎ снова запустить BackProp.
- ➏ Если  $Q(w, X^\ell)$  или  $Q(w, X^k)$  существенно ухудшился, то вернуть последние удалённые связи и выйти.

Отбор признаков с помощью OBD — аналогично.

Суммарная значимость признака:  $S_j = \sum_{h=1}^H S_{jh}$ .

**Эмпирический опыт:** результат постепенного прореживания обычно лучше, чем BackProp изначально прореженной сети.

- Нейрон = линейная классификация или регрессия.
- Нейронная сеть = суперпозиция нейронов с нелинейной функцией активации. Теоретически двух-трёх слоёв достаточно для решения очень широкого класса задач.
- BackProp = быстрое дифференцирование суперпозиций. Позволяет обучать сети практически любой конфигурации.
- Некоторые меры по улучшению сходимости и качества:
  - адаптивный градиентный шаг
  - функции активации типа ReLU
  - регуляризация и DropOut
  - пакетная нормализация (batch normalization)
  - инициализация нейронов как отдельных алгоритмов