



Национальный исследовательский  
Нижегородский государственный университет им. Н.И. Лобачевского  
Институт информационных технологий, математики и механики

Образовательный курс  
«Введение в глубокое обучение с использованием  
Intel® neon™ Framework»

# **Многослойные полностью связанные сети**

*При поддержке компании Intel*

Кустикова Валентина,  
к.т.н., ст.преп. каф. МОСТ ИИТММ,  
ННГУ им. Н.И. Лобачевского

# Содержание

---

- ❑ Детерминистская модель нейрона. Функции активации
- ❑ Общая структура модели многослойной полностью связанной нейронной сети
- ❑ Оптимизационная постановка задачи обучения многослойной полносвязной нейронной сети. Функция ошибки
- ❑ Метод обратного распространения ошибки
- ❑ Последовательный и пакетный режимы обучения
- ❑ Эвристические рекомендации по повышению производительности метода обратного распространения ошибки

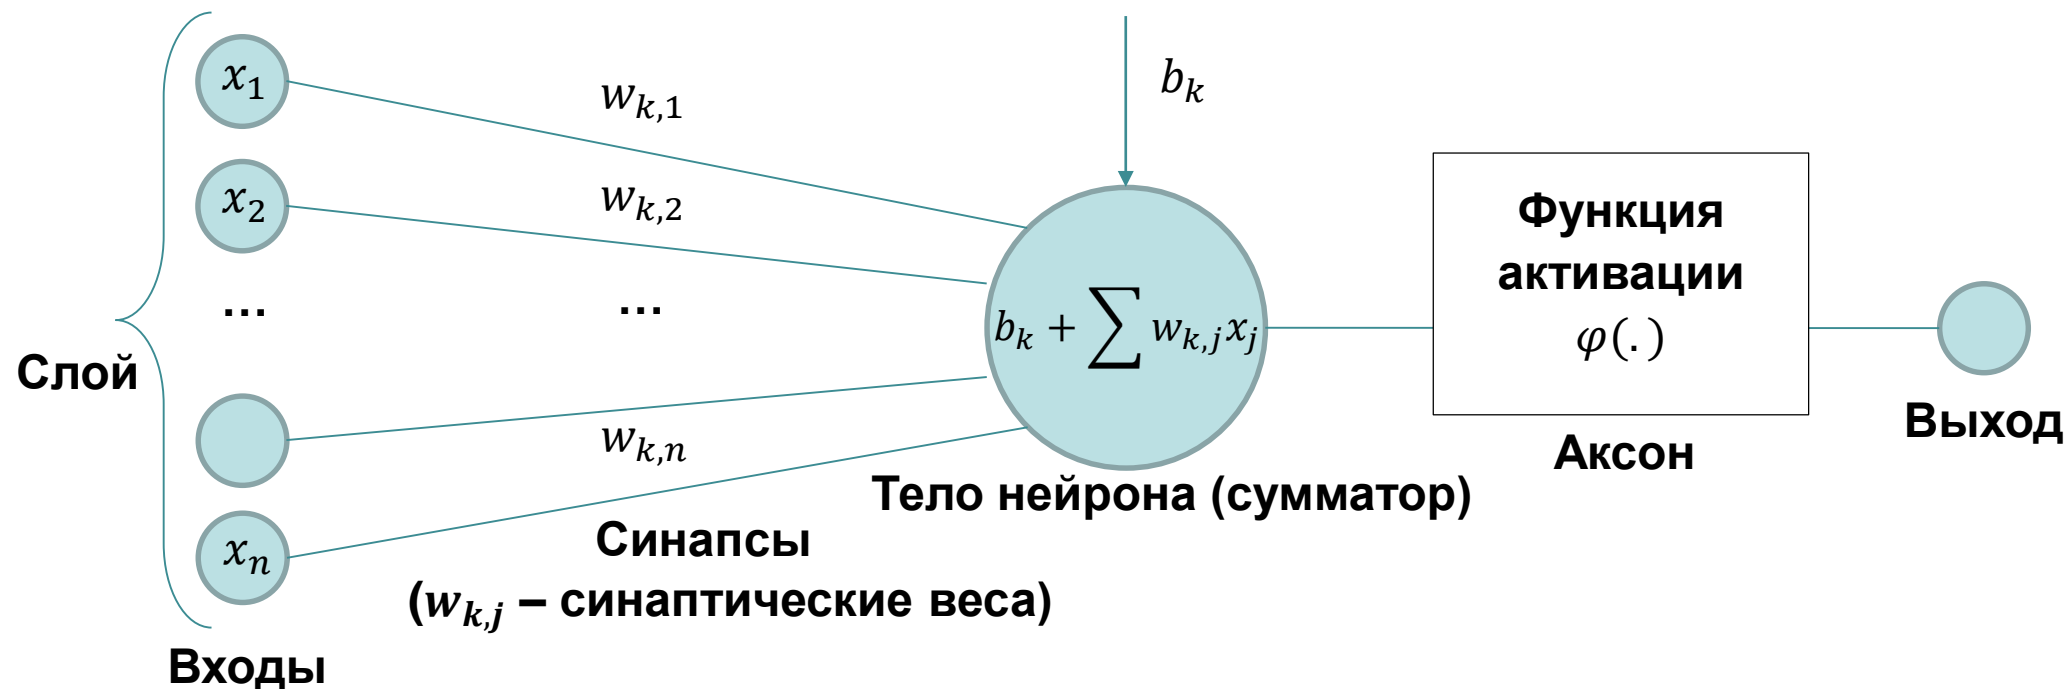


---

# ДЕТЕРМИНИСТСКАЯ МОДЕЛЬ НЕЙРОНА. ФУНКЦИИ АКТИВАЦИИ



# Детерминистская модель нейрона (1)



# Детерминистская модель нейрона (2)

- Модель нейрона состоит из трех основных компонент:
  - **Синапсы** – входные сигналы, каждый из которых характеризуется собственным **весом**
  - **Сумматор** – компонент, который складывает входные сигналы с учетом установленных синаптических весов
  - **Функция активации** – компонент, который ограничивает амплитуду выходного сигнала, в результате чего выход нейрона, как правило, лежит в отрезке  $[0,1]$  или  $[-1,1]$



# Детерминистская модель нейрона (3)

- Математическая модель нейрона:

$$u_k = \sum_{j=1}^n w_{k,j} x_j, \quad y_k = \varphi(u_k + b_k) \quad (1)$$

- В предположении, что  $v_k = u_k + b_k$ , указанная пара уравнений может быть записана следующим образом:

$$v_k = \sum_{j=0}^n w_{k,j} x_j, \quad y_k = \varphi(v_k), \quad (2)$$



где  $x_0 = 1$  – новый синапс, а  $w_{k,0} = b_k$  – его вес

- (1) и (2) – эквивалентные модели нейрона





# Функции активации (1)

- ❑ **Пороговая функция** (а). Описывает состояние «все или ничего». Применяется в задачах, требующих бинарного ответа
- ❑ **Кусочно-линейная функция** (б). Может рассматриваться как аппроксимация нелинейного усилителя



## Функции активации (2)

- **Сигмоидальная функция** ( $\nu$ ). Примерами таких функций могут служить логистическая функция и гиперболический тангенс
- **Положительная «срезка»** (Rectified Linear Unit, ReLU,  $\gamma$ )






---

# СТРУКТУРА МНОГОСЛОЙНОЙ ПОЛНОСВЯЗНОЙ СЕТИ




# Общая структура модели многослойной полностью связанной нейронной сети (1)

- Многослойная нейронная сеть содержит нейроны, которые распределены по **СЛОЯМ**




# Общая структура модели многослойной полностью связанной нейронной сети (2)

- В простейшем случае в сети существует **входной и выходной слою**, и сеть называется **однослойной**




# Общая структура модели многослойной полностью связанной нейронной сети (3)

- Если сигнал проходит от нейронов входного слоя к нейронам выходного, то такая сеть называется **сетью прямого распространения**



# Общая структура модели многослойной полностью связанной нейронной сети (4)

- ❑ Сеть может содержать множество скрытых слоев называется **многослойной**
- ❑ Если все узлы слоя соединены с узлами следующего слоя, то слой называется **полностью связным**
- ❑ Если данное условие выполнено для всех слоев сети, то сеть называется **полностью связной** или **полносвязной** (Fully-Connected Neural Network, FCNN)



Входной слой

Скрытые слои

Выходной слой

---

# ЗАДАЧА ОБУЧЕНИЯ НЕЙРОННОЙ ПОЛНОСВЯЗНОЙ СЕТИ



# Задача обучения нейронной сети

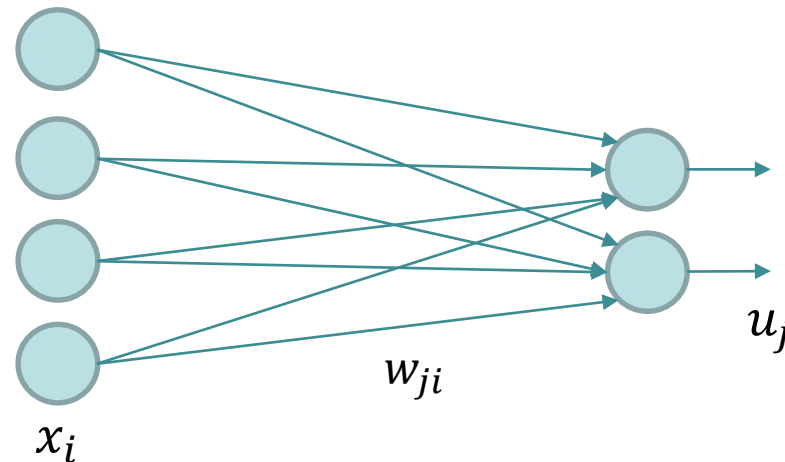
---

- **Цель обучения** – подобрать веса
- **Задача обучения** – задача минимизации **функции ошибки** или **функция стоимости** (cost function), отражающей разницу ожидаемого сигнала, полученного на выходе сети и фактического сигнала, соответствующего текущему входу, по всей обучающей выборке



# Квадратичная функция ошибки для однослойной нейронной сети (1)

- Рассмотрим однослойную нейронную сеть, содержащую  $N$  входных и  $M$  выходных нейронов



- Обучающая выборка  $\langle X, Y \rangle$ :
  - $L$  – число примеров в выборке,
  - $X$  – множество входных сигналов (векторов размерности  $N$ ),
  - $Y$  – множество векторов фактических выходных сигналов (векторов размерности  $M$ )



# Квадратичная функция ошибки для однослойной нейронной сети (2)

- Квадратичная функции ошибки (используется для задачи восстановления регрессии):

$$\begin{aligned} E &= \frac{1}{2} \sum_{k=1}^L \|y^k - u^k\|^2 = \frac{1}{2} \sum_{k=1}^L \sum_{j=1}^M (y_j^k - u_j^k)^2 \\ &= \frac{1}{2} \sum_{k=1}^L \sum_{j=1}^M \left( y_j^k - \varphi \left( \sum_{i=0}^N w_{ji} x_i^k \right) \right)^2, \end{aligned}$$

где  $y^k = (y_j^k)_{j=\overline{1,M}} \in Y$  – множество обучающих примеров, а  $u^k = (u_j^k)_{j=\overline{1,M}}$  – выход сети для входа  $x^k = (x_i^k)_{i=\overline{1,N}} \in X$

- Также вводится нормализация указанной метрики по числу примеров обучающей выборки  $L$

# Квадратичная функция ошибки для однослойной нейронной сети (3)


---

- Что изменится при переходе от однослойной полносвязной сети к двухслойной?



# Квадратичная функция ошибки для двухслойной нейронной сети (1)

- Рассмотрим двухслойную нейронную сеть:




- $w_{si}^{(1)}, w_{js}^{(2)}$  – веса синаптических связей
- Выходной сигнал нейрона скрытого слоя описывается следующим образом:

$$v_s = \varphi^{(1)} \left( \sum_{i=0}^N w_{si}^{(1)} x_i \right), s = \overline{0, K}, \text{ где } K \text{ – количество нейронов на скрытом слое}$$

# Квадратичная функция ошибки для двухслойной нейронной сети (2)

- Рассмотрим двухслойную нейронную сеть:



- Сигнал  $j$ -ого нейрона выходного слоя:

$$u_j = \varphi^{(2)} \left( \sum_{s=0}^K w_{js}^{(2)} v_s \right) = \varphi^{(2)} \left( \sum_{s=0}^K w_{js}^{(2)} \varphi^{(1)} \left( \sum_{i=0}^N w_{si}^{(1)} x_i \right) \right), j = \overline{1, M}.$$

# Квадратичная функция ошибки для двухслойной нейронной сети (3)

- Квадратичная функция ошибки для набора тренировочных примеров имеет вид:

$$E(w) = \frac{1}{2} \sum_{k=1}^L \sum_{j=1}^M (y_j^k - u_j^k)^2$$
$$= \frac{1}{2} \sum_{k=1}^L \sum_{j=1}^M \left( y_j^k - \varphi^{(2)} \left( \sum_{s=0}^K w_{js}^{(2)} \varphi^{(1)} \left( \sum_{i=0}^N w_{si}^{(1)} x_i^k \right) \right) \right)^2$$



# Оптимизационная постановка задачи обучения с квадратичной функцией ошибки

- Общая математическая постановка задачи обучения сети с квадратичной функцией ошибки:

$$\min_w E(w) = \min_w \left\{ \frac{1}{L} \sum_{k=1}^L \left\{ \frac{1}{2} \sum_{j=1}^M (y_j^k - u_j^k)^2 \right\} \right\}$$

- Квадратичная ошибка отражает разницу выхода сети разметки
- Квадратичная (Евклидова) ошибка применяется при решении **задачи восстановления регрессии**



# Оптимизационная постановка задачи обучения с кросс-энтропийной функцией ошибки

- Для **задачи классификации** в качестве функции ошибки выбирается **кросс-энтропия**. Постановка задачи обучения сети:

$$\min_w E(w) = \min_w \left\{ -\frac{1}{L} \sum_{k=1}^L \sum_{j=1}^M y_j^k \ln u_j^k \right\}$$

где  $y_j^k = 1 \leftrightarrow x^k$  принадлежит классу  $j$ , иначе  $y_j^k = 0$

- Является дифференцируемой аппроксимацией функции ошибки классификации «0-1»
- В качестве функции активации на последнем слое рекомендуется выбирать **функцию softmax**:

$$\varphi(u_j) = \frac{e^{u_j}}{\sum_{i=1}^M e^{u_i}}$$



---

# **МЕТОД ОБРАТНОГО РАСПРОСТРАНЕНИЯ ОШИБКИ**





# Метод обратного распространения ошибки (1)

- ❑ Метод обратного распространения ошибки определяет стратегию изменения параметров сети  $w$  в ходе обучения с использованием градиентных методов оптимизации
- ❑ Градиентные методы на каждом шаге уточняют значения параметров:

$$w(k + 1) = w(k) + \eta p(w)$$

- $\eta, 0 < \eta < 1$  – **скорость обучения** (learning rate) – «скорость» движения в направлении минимального значения функции,
  - $p(w)$  – направление в многомерном пространстве параметров нейронной сети
- ❑ В классическом методе обратного распространения ошибки направление движения совпадает с направлением антиградиента  $p(w) = -\nabla E(w)$




# Метод обратного распространения ошибки (2)

- ❑ **Инициализация синаптических весов сети**  
(случайным образом из некоторого распределения)
- ❑ Повторение следующих шагов для каждого примера тренировочного набора данных
  - 1. Прямой проход:**
    1. Вычисление значений выходных сигналов нейронов всех слоев
    2. Вычисление значений производных функций активации на каждом слое сети
  - 2. Обратный проход:**
    1. Вычисление значения целевой функции и ее градиента
    2. Корректировка синаптических весов
- ❑ **Критерии остановки:** число итераций метода (количество проходов по всему множеству примеров), достигнутая ошибка



# Метод обратного распространения ошибки на примере двухслойной сети (1)

- Рассмотрим процедуру вычисления производных и значений функции ошибки на примере двухслойной нейронной сети



- Функция ошибки:

$$E(w) = \frac{1}{2} \sum_{j=1}^M \left( y_j - \varphi^{(2)} \left( \sum_{s=0}^K w_{js}^{(2)} \varphi^{(1)} \left( \sum_{i=0}^N w_{si}^{(1)} x_i \right) \right) \right)^2$$

# Метод обратного распространения ошибки на примере двухслойной сети (2)

- Производная целевой функции по параметрам последнего слоя:

$$\frac{\partial E}{\partial w_{js}^{(2)}} = \frac{\partial \left( \frac{1}{2} \sum_{j=1}^M \left( y_j - \varphi^{(2)} \left( \sum_{s=0}^K w_{js}^{(2)} \varphi^{(1)} \left( \sum_{i=0}^N w_{si}^{(1)} x_i \right) \right) \right)^2 \right)}{\partial w_{js}^{(2)}}$$

$u_j$

$$= - (y_j - u_j) \frac{d\varphi^{(2)}(g_j)}{dg_j} v_s = \delta_j^{(2)} v_s,$$
$$g_j = \sum_{s=0}^K w_{js}^{(2)} v_s, \quad \delta_j^{(2)} = \frac{\partial E(w)}{\partial g_j}$$



# Метод обратного распространения ошибки на примере двухслойной сети (2)

- Производная целевой функции по параметрам последнего слоя:

$$\frac{\partial E}{\partial w_{js}^{(2)}} = \frac{\partial \left( \frac{1}{2} \sum_{j=1}^M \left( y_j - \varphi^{(2)} \left( \sum_{s=0}^K w_{js}^{(2)} \varphi^{(1)} \left( \sum_{i=0}^N w_{si}^{(1)} x_i \right) \right) \right)^2 \right)}{\partial w_{js}^{(2)}}$$

$v_s$

$$= - (y_j - u_j) \frac{d\varphi^{(2)}(g_j)}{dg_j} v_s = \delta_j^{(2)} v_s,$$

$$g_j = \sum_{s=0}^K w_{js}^{(2)} v_s, \quad \delta_j^{(2)} = \frac{\partial E(w)}{\partial g_j}$$



# Метод обратного распространения ошибки на примере двухслойной сети (2)

- Производная целевой функции по параметрам последнего слоя:

$$\frac{\partial E}{\partial w_{js}^{(2)}} = \frac{\partial \left( \frac{1}{2} \sum_{j=1}^M \left( y_j - \varphi^{(2)} \left( \sum_{s=0}^K w_{js}^{(2)} \varphi^{(1)} \left( \sum_{i=0}^N w_{si}^{(1)} x_i \right) \right) \right)^2 \right)}{\partial w_{js}^{(2)}}$$

$v_s$

$$= -(y_j - u_j) \frac{d\varphi^{(2)}(g_j)}{dg_j} v_s = \delta_j^{(2)} v_s,$$

$$g_j = \sum_{s=0}^K w_{js}^{(2)} v_s, \quad \delta_j^{(2)} = \frac{\partial E(w)}{\partial g_j}$$



# Метод обратного распространения ошибки на примере двухслойной сети (3)

- Производная целевой функции по параметрам скрытого слоя:

$$\frac{\partial E}{\partial w_{si}^{(1)}} = \frac{\partial \left( \frac{1}{2} \sum_{j=1}^M \left( y_j - \varphi^{(2)} \left( \sum_{s=0}^K w_{js}^{(2)} \varphi^{(1)} \left( \sum_{i=0}^N w_{si}^{(1)} x_i \right) \right) \right)^2 \right)}{\partial w_{si}^{(1)}}$$

$$= - \sum_{j=1}^M (y_j - u_j) \frac{d\varphi^{(2)}(g_j)}{dg_j} \frac{dg_j(v_s)}{dv_s} \frac{d\varphi^{(1)}(f_s)}{df_s} x_i =$$

$$= - \sum_{j=1}^M (y_j - u_j) \frac{d\varphi^{(2)}(g_j)}{dg_j} w_{js}^{(2)} \frac{d\varphi^{(1)}(f_s)}{df_s} x_i = \delta_s^{(1)} x_i,$$

$$f_s = \sum_{i=0}^N w_{si}^{(1)} x_i, \quad \delta_s^{(1)} = \frac{\partial E(w)}{\partial f_s}$$

# Метод обратного распространения ошибки на примере двухслойной сети (3)

- Производная целевой функции по параметрам скрытого слоя:

$$\frac{\partial E}{\partial w_{si}^{(1)}} = \frac{\partial \left( \frac{1}{2} \sum_{j=1}^M \left( y_j - \varphi^{(2)} \left( \sum_{s=0}^K w_{js}^{(2)} \varphi^{(1)} \left( \sum_{i=0}^N w_{si}^{(1)} x_i \right) \right) \right)^2 \right)}{\partial w_{si}^{(1)}}$$

$$= - \sum_{j=1}^M (y_j - u_j) \frac{d\varphi^{(2)}(g_j)}{dg_j} \frac{dg_j(v_s)}{dv_s} \frac{d\varphi^{(1)}(f_s)}{df_s} x_i =$$

$$= - \sum_{j=1}^M (y_j - u_j) \frac{d\varphi^{(2)}(g_j)}{dg_j} w_{js}^{(2)} \frac{d\varphi^{(1)}(f_s)}{df_s} x_i = \delta_s^{(1)} x_i,$$

$$f_s = \sum_{i=0}^N w_{si}^{(1)} x_i, \quad \delta_s^{(1)} = \frac{\partial E(w)}{\partial f_s}$$



# Метод обратного распространения ошибки на примере двухслойной сети (3)

- Производная целевой функции по параметрам скрытого слоя:

$$\begin{aligned} \frac{\partial E}{\partial w_{si}^{(1)}} &= \frac{\partial \left( \frac{1}{2} \sum_{j=1}^M \left( y_j - \varphi^{(2)} \left( \sum_{s=0}^K w_{js}^{(2)} \varphi^{(1)} \left( \sum_{i=0}^N w_{si}^{(1)} x_i \right) \right) \right)^2 \right)}{\partial w_{si}^{(1)}} \\ &= - \sum_{j=1}^M (y_j - u_j) \frac{d\varphi^{(2)}(g_j)}{dg_j} \frac{dg_j(v_s)}{dv_s} \frac{d\varphi^{(1)}(f_s)}{df_s} x_i = \\ &= - \sum_{j=1}^M (y_j - u_j) \frac{d\varphi^{(2)}(g_j)}{dg_j} w_{js}^{(2)} \frac{d\varphi^{(1)}(f_s)}{df_s} x_i = \delta_s^{(1)} x_i, \\ f_s &= \sum_{i=0}^N w_{si}^{(1)} x_i, \quad \delta_s^{(1)} = \frac{\partial E(w)}{\partial f_s} \end{aligned}$$

# Метод обратного распространения ошибки на примере двухслойной сети (3)

- Производная целевой функции по параметрам скрытого слоя:

$$\begin{aligned} \frac{\partial E}{\partial w_{si}^{(1)}} &= \frac{\partial \left( \frac{1}{2} \sum_{j=1}^M \left( y_j - \varphi^{(2)} \left( \sum_{s=0}^K w_{js}^{(2)} \varphi^{(1)} \left( \sum_{i=0}^N w_{si}^{(1)} x_i \right) \right) \right)^2 \right)}{\partial w_{si}^{(1)}} \\ &= - \sum_{j=1}^M (y_j - u_j) \frac{d\varphi^{(2)}(g_j)}{dg_j} \frac{dg_j(v_s)}{dv_s} \frac{d\varphi^{(1)}(f_s)}{df_s} x_i = \\ &= - \sum_{j=1}^M (y_j - u_j) \frac{d\varphi^{(2)}(g_j)}{dg_j} w_{js}^{(2)} \frac{d\varphi^{(1)}(f_s)}{df_s} x_i = \delta_s^{(1)} x_i, \\ f_s &= \sum_{i=0}^N w_{si}^{(1)} x_i, \quad \delta_s^{(1)} = \frac{\partial E(w)}{\partial f_s} \end{aligned}$$

# Метод обратного распространения ошибки на примере двухслойной сети (3)

- Производная целевой функции по параметрам скрытого слоя:

$$\begin{aligned} \frac{\partial E}{\partial w_{si}^{(1)}} &= \frac{\partial \left( \frac{1}{2} \sum_{j=1}^M \left( y_j - \varphi^{(2)} \left( \sum_{s=0}^K w_{js}^{(2)} \varphi^{(1)} \left( \sum_{i=0}^N w_{si}^{(1)} x_i \right) \right) \right)^2 \right)}{\partial w_{si}^{(1)}} \\ &= - \sum_{j=1}^M (y_j - u_j) \frac{d\varphi^{(2)}(g_j)}{dg_j} \frac{dg_j(v_s)}{dv_s} \frac{d\varphi^{(1)}(f_s)}{df_s} x_i = \\ &= - \sum_{j=1}^M (y_j - u_j) \frac{d\varphi^{(2)}(g_j)}{dg_j} w_{js}^{(2)} \frac{d\varphi^{(1)}(f_s)}{df_s} x_i = \delta_s^{(1)} x_i, \\ f_s &= \sum_{i=0}^N w_{si}^{(1)} x_i, \quad \delta_s^{(1)} = \frac{\partial E(w)}{\partial f_s} \end{aligned}$$

# Метод обратного распространения ошибки на примере двухслойной сети (4)

- Описание градиента по параметрам выходного и скрытого слоев имеют идентичную структуру:

$$\frac{\partial E}{\partial w_{js}^{(2)}} = \delta_j^{(2)} v_s$$
$$\frac{\partial E}{\partial w_{si}^{(1)}} = \delta_s^{(1)} x_i$$


Начальный нейрон  
взвешенной связи

Величина погрешности,  
перенесенной на узел,  
с которым эта связь  
установлена

# Метод обратного распространения ошибки на примере двухслойной сети (5)

## 1. Прямой проход:

- Вычисление  $v_s$  и  $u_j$
- Вычисление  $\frac{d\phi^{(2)}(g_j)}{dg_j}$  и  $\frac{d\phi^{(1)}(f_s)}{df_s}$



## 2. Обратный проход:

- Вычисление целевой функции  $E$  и ее градиента  $\frac{\partial E}{\partial w_{js}^{(2)}}$  и  $\frac{\partial E}{\partial w_{si}^{(1)}}$
- Коррекция весов  $w(k + 1) = w(k) - \eta \nabla E(w)$

# Сходимость метода обратного распространения ошибки (1)

---

- ❑ Доказательства сходимости метода обратного распространения ошибки не существует
- ❑ Разумное условие остановки: евклидова норма вектора градиента достигла достаточно малых значений
- ❑ Для выполнения указанного критерия может потребоваться большое количество итераций метода обратного распространения



# Сходимость метода обратного распространения ошибки (2)

---

- ❑ Более слабое условие остановки: в течение полного цикла предъявления всех обучающих примеров абсолютное значение изменения ошибки достаточно мало (в пределах от 0.1 до 1%)
- ❑ Условие не гарантирует, что полученная сеть обладает хорошими обобщающими свойствами



# Последовательный и пакетный режимы обучения (1)


- В процессе обучения многослойной полносвязной нейронной сети ей многократно предъявляется predetermined множество обучающих примеров
- Один полный цикл предъявления полного набора примеров называется **эпохой** (epoch)
  - При обучении может выполняться несколько таких циклов до момента стабилизации синаптических весов, либо достижения минимального значения функции ошибки
  - При реализации эпох целесообразно изменять порядок примеров в обучающей выборке, обеспечивая стохастический поиск






# Последовательный и пакетный режимы обучения (2)

- Режимы реализации метода обратного распространения ошибки:
  - **Последовательный (или стохастический) режим (sequential or stochastic mode)**. В указанном режиме корректировка весов выполняется после предъявления каждого примера обучающей выборки



# Последовательный и пакетный режимы обучения (3)

- Режимы реализации метода обратного распространения ошибки:
  - **Пакетный режим (batch mode)**. В данном режиме корректировка весов осуществляется по всем примерам эпохи



# Последовательный и пакетный режимы обучения (4)

- Функция ошибки для всего набора тренировочных данных, нормированная по числу примеров выборки:

$$E(w) = \frac{1}{L} \sum_{k=1}^L \left\{ \frac{1}{2} \sum_{j=1}^M (y_j^k - u_j^k)^2 \right\}$$

- Корректировка весов проводится по всему набору данных. Для двухслойной полностью связанной сети нейронной сети формулы корректировки:

$$\Delta w_{js}^{(2)} = -\frac{\eta}{L} \sum_{k=1}^L (y_j^k - u_j^k) \frac{d\varphi^{(2)}(g_j)}{dg_j} \Big|_{x^k} v_s \Big|_{x^k},$$

$$\Delta w_{si}^{(1)} = -\frac{\eta}{L} \sum_{k=1}^L \sum_{j=1}^M (y_j - u_j) \frac{d\varphi^{(2)}(g_j)}{dg_j} \Big|_{x^k} \frac{dg_j(v_s)}{dv_s} \Big|_{x^k} \frac{d\varphi^{(1)}(f_s)}{df_s} \Big|_{x^k} x_i^k$$

# Последовательный и пакетный режимы обучения (5)

---

- ❑ **Последовательный режим обучения (*sequential mode*)**
  - Медленный
- ❑ **Пакетный режим обучения (*batch mode*)**
  - Быстрый и стабильный
  - Может «застревать» в локальных минимумах



# Последовательный и пакетный режимы обучения (6)

- Компромисс – применение мини-пакетов (mini-batch)
  - Тренировочное множество примеров разбивается на мини-пакеты
  - Прямой проход выполняется для всего множества примеров из мини-пакета
  - Обратный проход и коррекция весов осуществляется после обработки мини-пакета



# Эвристические рекомендации по повышению производительности

## □ *Максимизация информативности*

- Наличие кардинально разных примеров в обучающей выборке (не только визуально воспринимаемые различия внешнего вида, но и различия в значениях функции ошибки)

## □ *Функция активации*

- Полносвязная сеть обучается быстрее, если функция активации является антисимметричной  $\varphi(-x) = -\varphi(x)$

## □ *Нормализация входов*

- Все входные переменные следует предварительно нормализовать по всему обучающему множеству



# Заключение

---

- ❑ Введена модель нейрона
- ❑ Рассмотрена общая схема построения полносвязных нейронных сетей
- ❑ Введена математическая постановка задачи поиска весов полносвязной сети
- ❑ Рассмотрена общая схема метода обратного распространения ошибки для обучения параметров сети
- ❑ Далее рассматривается пример использования глубоких полносвязных сетей для решения задачи компьютерного зрения средствами Intel® neon™ Framework



# Основная литература

---

- ❑ Хайкин С. Нейронные сети. Полный курс. – М.: Издательский дом «Вильямс». – 2006. – 1104 с.
- ❑ Осовский С. Нейронные сети для обработки информации. – М.: Финансы и статистика. – 2002. – 344 с.
- ❑ Goodfellow I., Bengio Y., Courville A. Deep Learning. – MIT Press. – 2016. – [<http://www.deeplearningbook.org>].





# Авторский коллектив

---

- ❑ **Кустикова Валентина Дмитриевна**  
к.т.н., ст.преп. каф. МОСТ ИИТММ,  
ННГУ им. Н.И. Лобачевского  
[valentina.kustikova@itmm.unn.ru](mailto:valentina.kustikova@itmm.unn.ru)
- ❑ **Жильцов Максим Сергеевич**  
магистрант каф. МОСТ ИИТММ,  
ННГУ им. Н.И. Лобачевского  
[zhiltsov.max35@gmail.com](mailto:zhiltsov.max35@gmail.com)
- ❑ **Золотых Николай Юрьевич**  
д.ф.-м.н., проф. каф. АГДМ ИИТММ,  
ННГУ им. Н.И. Лобачевского  
[nikolai.zolotykh@itmm.unn.ru](mailto:nikolai.zolotykh@itmm.unn.ru)

