



Санкт-Петербургский
государственный
университет

Применение дискретизованных нейросетей

к. ф.-м. н. ст. преп. каф. информатики СПбГУ
Салищев Сергей Игоревич



Основные тезисы

- Нейросеть эффективно вычислима
 - Нейрочипы
- Нейросеть легко интерпретируема
 - Ансамбль деревьев решений
- Нейросеть – дискретный объект
 - Шум квантования
 - Информационная емкость
- Нейросеть эффективно обучается
 - Пакетный стохастический градиентный спуск
 - Остаточные сети и пакетная нормализация



Пример: Система беспутниковой навигации

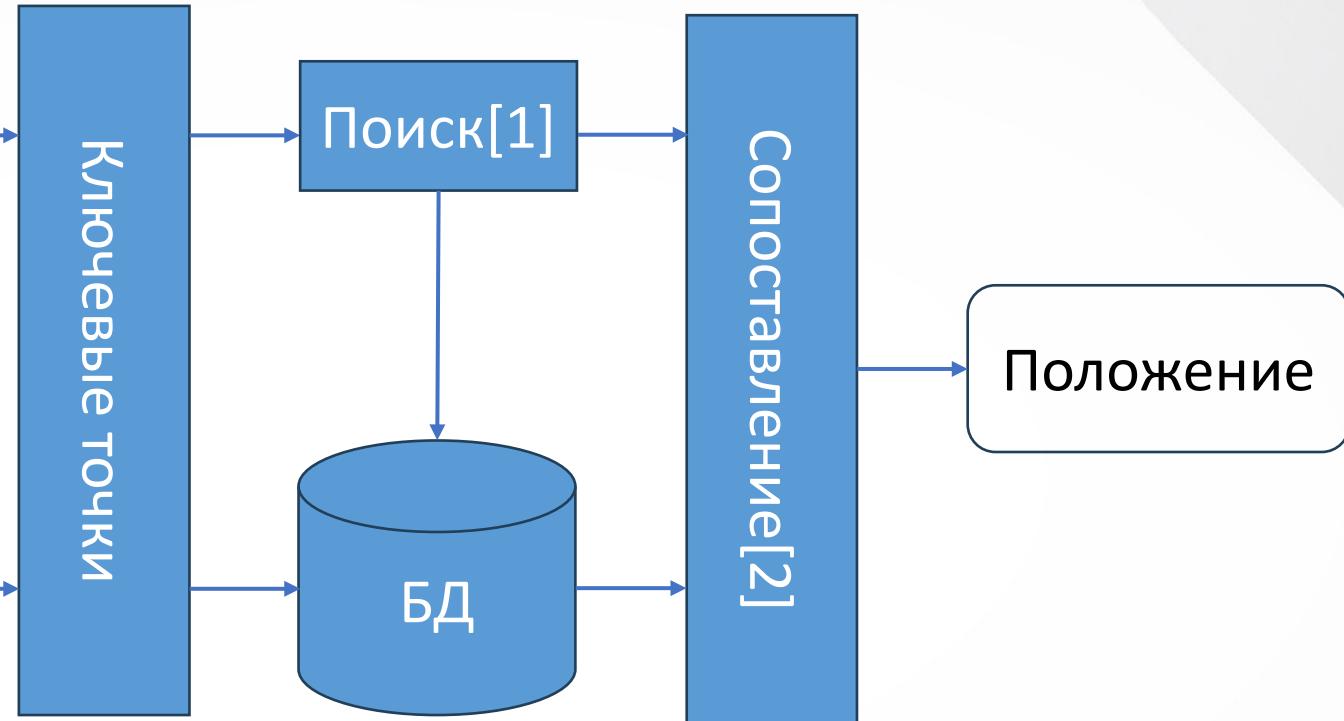
Камера ЛА



Аэросъемка*



*yandex.ru



[1] Yang Y., Newsam S. Geographic image retrieval using local invariant features //IEEE transactions on geoscience and remote sensing. – 2012. – Т. 51. – №. 2. – С. 818-832.

[2] Xiong Z., Zhang Y. A critical review of image registration methods //International Journal of Image and Data Fusion. – 2010. – Т. 1. – №. 2. – С. 137-158.



Добавляем нейросеть

- Основные недостатки системы на основе классических алгоритмов машинного зрения
 - Высокая вычислительная сложность сопоставления из-за низкого качества признаков
 - Низкая точность/полнота поиска
 - Расчеты на CPU
- Заменяем на нейросеть
 - Поиск ключевых точек и вычисление признаков [1]
 - Сопоставление (не обязательно) [2]

[1] Song W., Li S., Benediktsson J. A. Deep hashing learning for visual and semantic retrieval of remote sensing images //IEEE Transactions on Geoscience and Remote Sensing. – 2020. – Т. 59. – №. 11. – С. 9661-9672.

[2] Nassar A. et al. A deep CNN-based framework for enhanced aerial imagery registration with applications to UAV geolocalization //Proceedings of the IEEE conference on computer vision and pattern recognition workshops. – 2018. – С. 1513-1523.



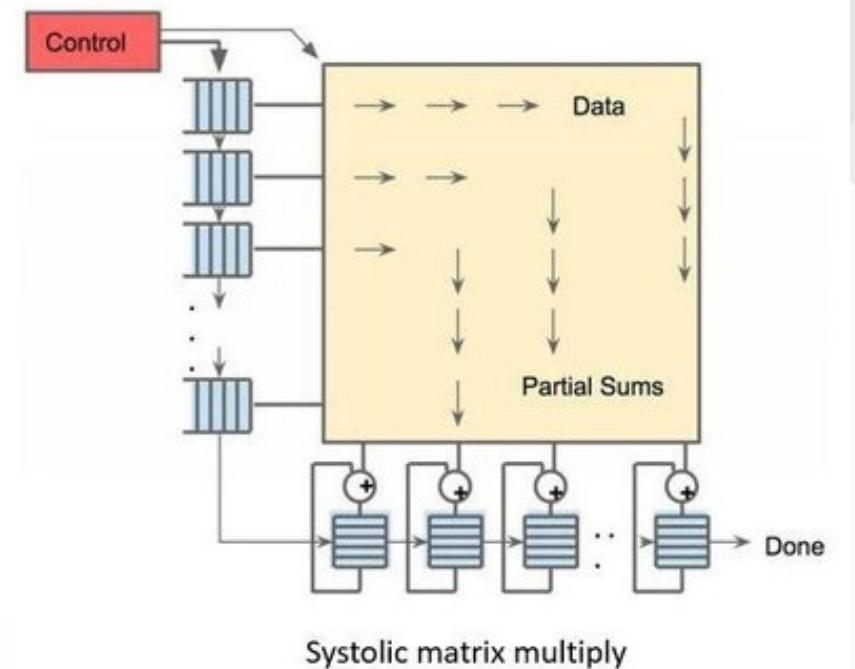
Пример встроенной вычислительной платформы

- Rockchip <https://www.rock-chips.com> RK3566/RK3568, RK3588, RK3562
 - 4-8 ядер ARM Cortex-A 1-2 ГГц
 - GPU ARM
 - Типичное энергопотребление 5Вт, макс. 20Вт
- Примерный вычислительный бюджет
 - CPU – 4 GFLOPS = $4 \cdot 10^9$ оп/с, FP32 (Процессор)
 - GPU – 40 GFLOPS = $4 \cdot 10^{10}$ оп/с, FP32 (Графический ускоритель)
 - TPU – 4 TOPS = $4 \cdot 10^{12}$ оп/сек, 8 бит MAD (Нейрочип)
- Практическое определение Нейросети?
 - Все что вычисляется на нейрочипе



Почему TPU в 1000 раз быстрее CPU

- Пониженная точность вычислений
- Однородные матричные вычисления
- Кэширование данных на чипе
- Сверхширокий интерфейс локальной памяти





Средства разработки Rockchip

- Обучение нейросети
 - PyTorch, TensorFlow, etc
- Промежуточный формат ONNX
- Прикладной интерфейс RKNN-Toolkit2
 - <https://github.com/airockchip/rknn-toolkit2>
 - Языки встроенной платформы C/C++, Python
 - ОС Linux, Android
- Отладка и симуляция на ПК RKNPu2
 - <https://github.com/airockchip/rknn-toolkit2/tree/master/rknpu2>



Так что же такое нейросеть

- Непрерывный и гладкий объект

$$x_{i+1} = f(W_i x_i + b_i)$$
$$x_i \in R^{n_i}, f \in C^1$$

- Матрица W имеет разреженную блочную периодическую структуру
- Обучается градиентным спуском
- f – произвольная гладкая функция кроме степенной

Пусть $L(\theta) \rightarrow \min$ - целевая функция, γ – скорость обучения

$$g_t = \nabla_{\theta} L(\theta_{t-1})$$
$$\theta_t = \theta_{t-1} - \gamma_t g_t$$



Свойства нейросетей

- Нейросеть - универсальный ε аппроксиматор для любых интегрируемых по Лебегу функций нескольких переменных, нелинейность любая кроме полинома
 - Достаточно 3 слоев (ширина не ограничена) [1]
 - Достаточно $n + 1$ каналов (глубина не ограничена) [2]

[1] Ismailov V. E. A three layer neural network can represent any multivariate function //Journal of Mathematical Analysis and Applications. – 2023. – Т. 523. – №. 1. – С. 127096.

[2] Kratsios A., Papon L. Universal approximation theorems for differentiable geometric deep learning //The Journal of Machine Learning Research. – 2022. – Т. 23. – №. 1. – С. 8896-8968.



Мотивация глубоких нейросетей

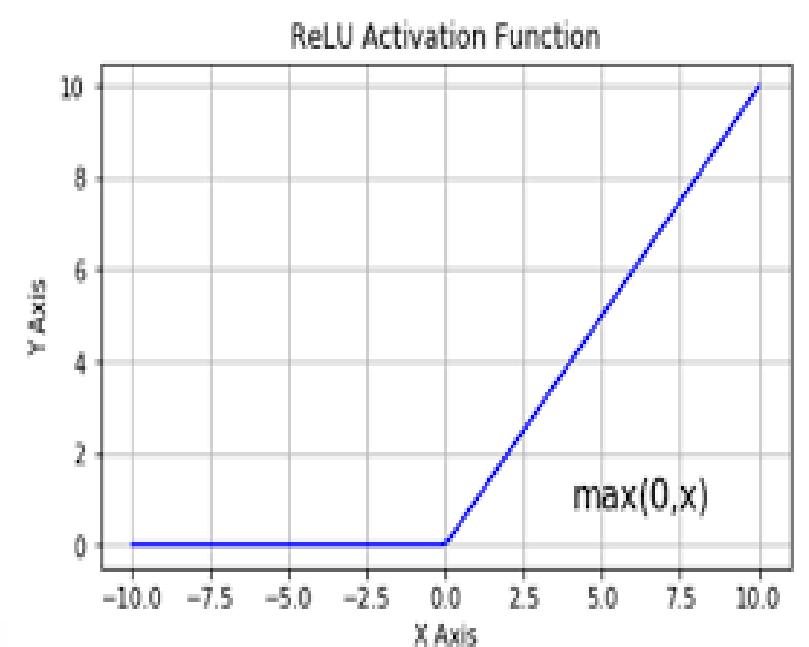
- Уменьшение размерности внутренних слоев за счет факторизации матриц W
 - Обучение глубоких нейросетей неустойчиво из-за исчезновения градиента
- Качественно обученная глубокая нейросеть – эффективный метод ускорения вычислений для любых алгоритмов!



Убираем гладкость

- Упрощаем нелинейность
- $f(x) = \text{ReLU}(x) = \max(0, x)$
- Сеть с ReLU эквивалентна дереву решений[1]

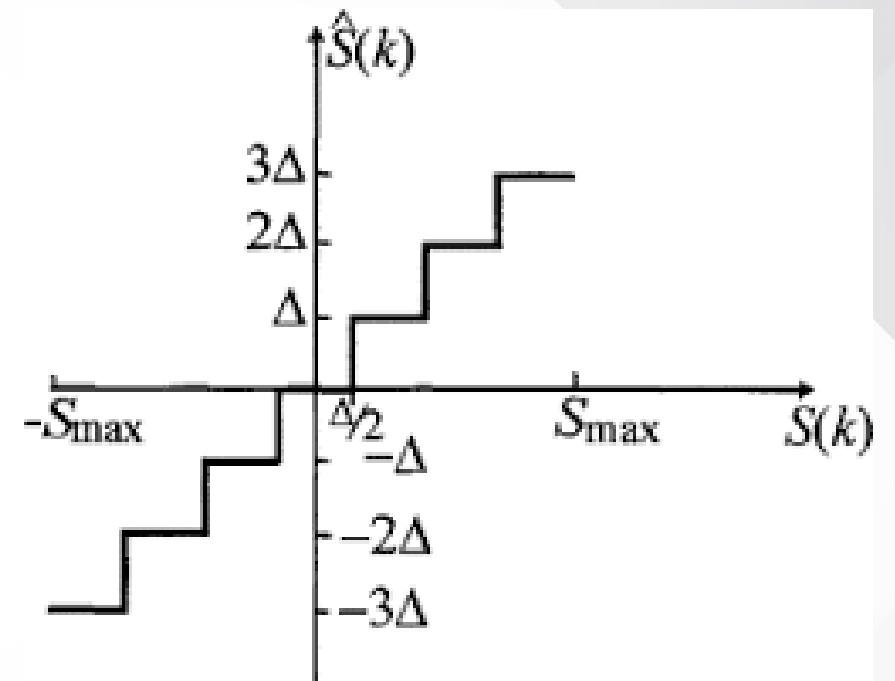
[1] Aytekin C. Neural Networks are Decision Trees //arXiv preprint arXiv:2210.05189. – 2022.





Убираем непрерывность

- $x_{i+1} = f((W_i + u_i)x_i + b_i) + v_i$
 - u_i, v_i – шум
- Вычисления с фиксированной точкой малой разрядности
 - Шум – погрешность округления
 - Сокращение длины арифметического переноса между разрядами
- Спайковые сети
 - Моделирование биологических нейросетей
- Вычисления в памяти
 - Нейросети на чипе
 - Физическая нечеткая логика





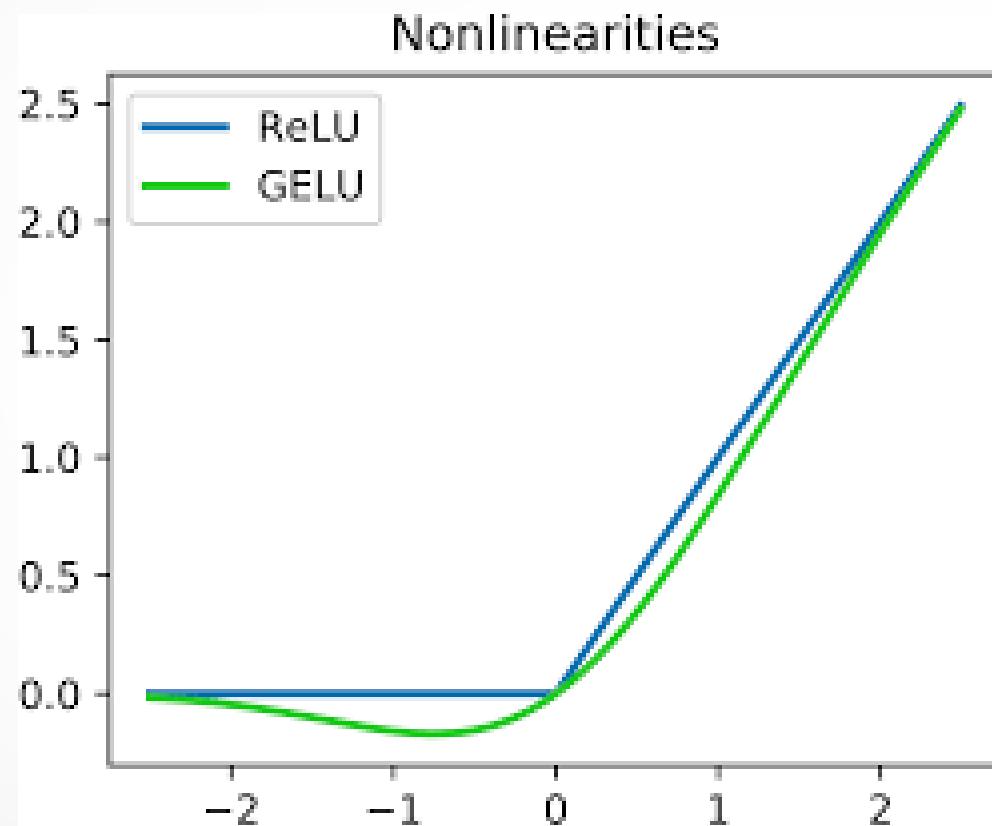
Градиентный спуск? Контрастное обучение

- В биологических нейросетях градиентный спуск (пока) не найден[1]
- Как тренировать нейросети без ГС[1]?
 - Послойное контрастное обучение
 - Мешок признаков
 - Сначала генерируем признаки, потом вешаем метки
 - Вероятность линейного разделения кластеров $\rightarrow 1$ с ростом числа признаков
 - Как научиться попадать в мишень
 1. Научится попадать кучно
 2. Сдвинуть прицел на центр мишени
- Градиентный спуск (в разы) быстрее
- Обучение нейросетей в природе интерпретируется как контрастное обучение

[1] Hinton G. The forward-forward algorithm: Some preliminary investigations //arXiv preprint arXiv:2212.13345. – 2022.



Регуляризация, в поисках потерянной гладкости





Пакетный Стохастический градиент

$$L(w) = \frac{1}{n} \sum_i L(w, x_{(i)})$$

$$\nabla L(w) = \frac{1}{n} \sum_i \nabla L(w, x_{(i)}) \rightarrow E \nabla L(w, x_{(i)}), n \rightarrow \infty$$

Основная мотивация пакетного (batch) градиента – распараллеливание обучения для более эффективных вычислений

Требуется непрерывность $E \nabla L(w, x_{(i)})$ а не $\nabla L(w)$

Устойчивость к малому шуму в данных \rightarrow Непрерывность и Ограниченная вариация EL ?

Ограниченная вариация $EL \rightarrow$ Гладкость EL почти везде



Основные причины неустойчивого обучения

- Спящие нейроны

$$(x_{i,k})_t = Const$$

- Пропадающий градиент в результате декорреляции

$$x_t \sim RV$$



Улучшение устойчивости обучения

- Групповая нормализация (batch norm) I

$$b_{i,k} = -EW_{i,k}x_i$$

- Остаточные сети (residual network, skip connection) II

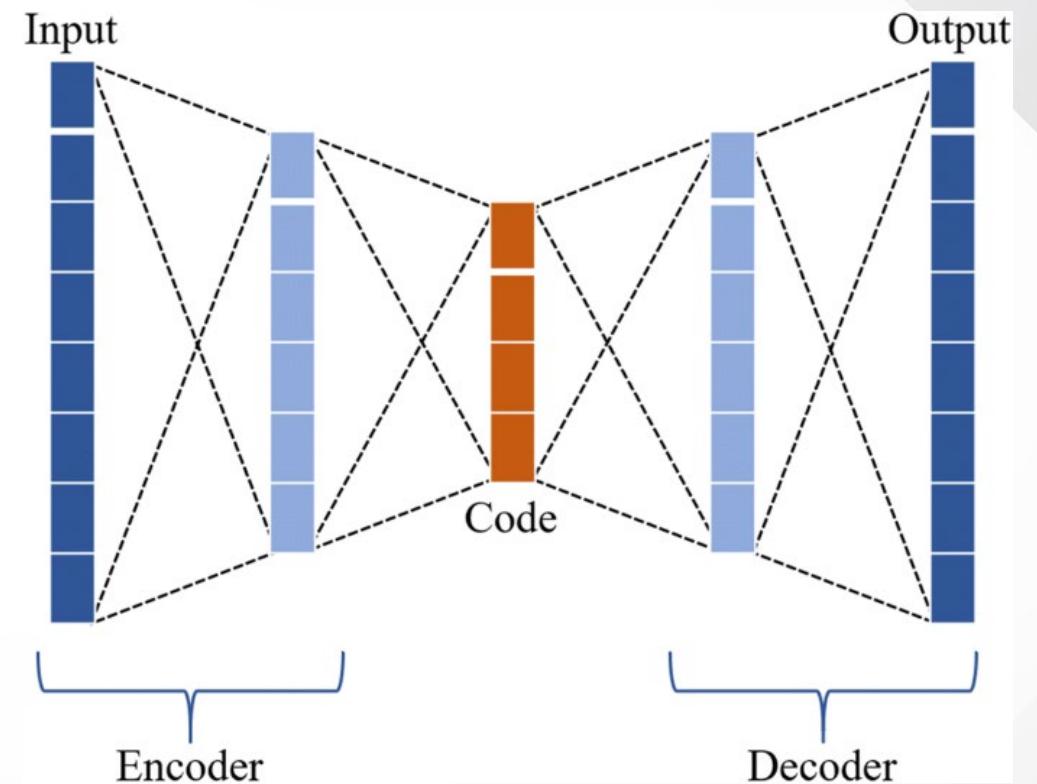
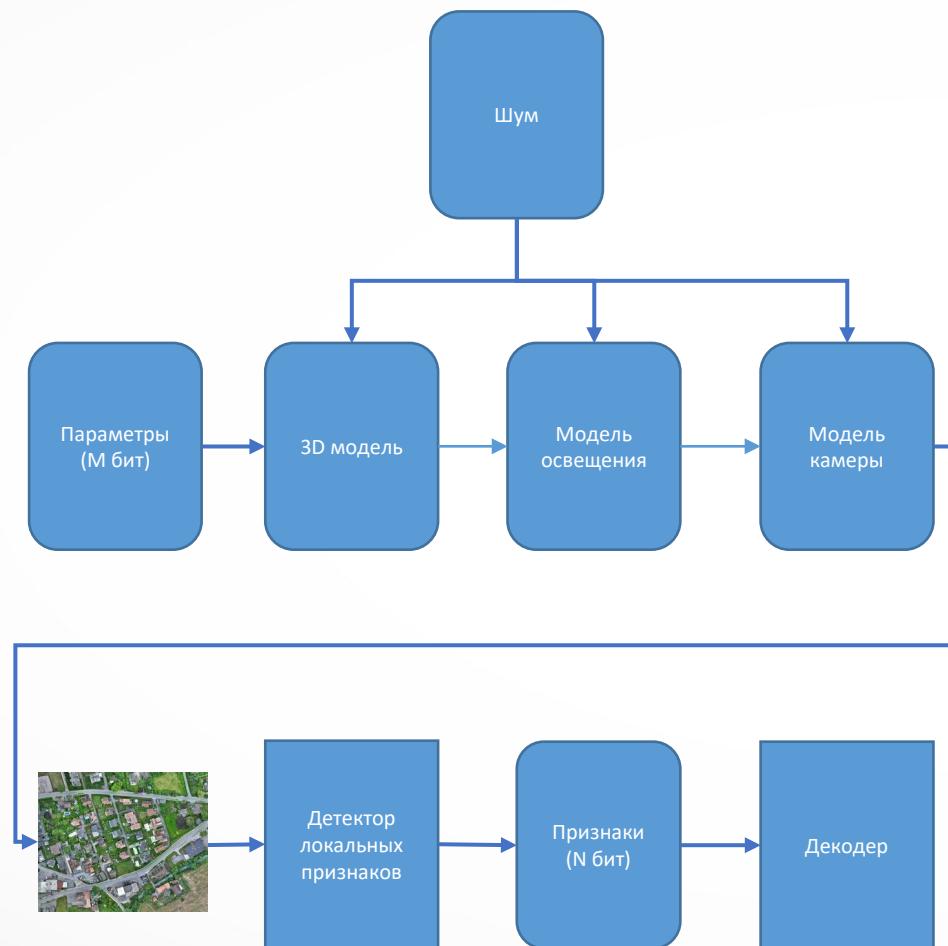
$$b_{i,k} = -\min W_{i,k}x_i$$

- Разобьём все сдвиги в архитектуре сети на типы I и II
- Фактически $\theta = W$



Метафора декодирования

для выбора архитектуры сети





Оптимальный код. Бустинг

- Каждый слой сети – непрерывный канал передачи данных с шумом округления
- Скрытое представление – $[M, N]$ код коррекции ошибок
 - Если шум не коррелирован с параметрами, то для достаточно большого N случайный код декодируется без ошибок с $P = 1 - \varepsilon$
- Каждый бит скрытого представления – слабый классификатор
 - Чем больше классов тем длиннее код можно построить в явном виде
- Унитарный (One-hot) код – бинарный классификатор один ко многим
 - Несбалансированный
 - Экспоненциальный рост с ростом числа классов
- Можно ли лучше?
 - Нейросети = деревья решений
 - Бустинг – построение сильного классификатора из слабых
 - Обучение нейросетевого полносвязного декодера = Нейробустинг



Выводы

- Основные практические достоинства нейросетей
 - Вычислительная эффективность вывода
 - Простота обучения
 - Возможность использования предобученных весов
- Основные практические недостатки нейросетей
 - Зависимость результата от обучающих данных
 - Необходимость сбора и разметки большого количества обучающих данных (в большинстве современных сценариев обучения)
 - Высокая вычислительная сложность обучения
 - Сложность проверки устойчивости и робастности решений



Дополнительная литература

- [1] Aggarwal C. C. et al. Neural networks and deep learning //Springer. – 2023
- [2] Moser S. M. Information theory, 6-th ed. //Lecture Notes. – 2018.
- [3] David A. Patterson, John L. Hennessy. Computer Organization and Design RISC-V Edition The Hardware Software Interface, 2nd Edition // Elsevier Science. – 2020.