



**ЦЕНТРАЛЬНЫЙ  
УНИВЕРСИТЕТ**



# Искусственный интеллект и математические законы

**Владимир Спокойный**


- Научный руководитель лаборатории теоретических основ моделей искусственного интеллекта ВШЭ
- Руководитель образовательной программы «Математика машинного обучения» ВШЭ & Сколтеха
- Академический консультант Центрального университета

17.04.2026


# Наш план на сегодня




Можно ли **просто и понятно** объяснить, что именно ИИ делает?



Подчиняются ли сложные ИИ-модели, такие как глубинные сети, генеративные и большие языковые модели, **математическим законам**?



Если **да**, можно ли **просто** их сформулировать, объяснить, проверить?




Могут ли эти законы помочь в понимании **пределов, сферы применимости, надежности, уровня доверия** и других свойств ИИ?

# Что есть ИИ?

Что есть ИИ на самом деле?

# Что есть ИИ?


Что есть ИИ на самом деле?



Очень упрощенный ответ

# Что есть ИИ?

Что есть ИИ на самом деле?




Очень упрощенный ответ

ИИ — это компьютерная программа, располагающая большой вычислительной мощностью, гигантской памятью и доступом к большим массивам данных

# Что есть ИИ?

## Что есть ИИ на самом деле?




Очень упрощенный ответ

ИИ — это **компьютерная программа**, располагающая большой **вычислительной мощностью**, гигантской **памятью** и доступом к большим **массивам данных**

## Что ИИ делает?

# Что есть ИИ?


## Что есть ИИ на самом деле?



Очень упрощенный ответ

ИИ — это **компьютерная программа**, располагающая большой **вычислительной мощностью**, гигантской **памятью** и доступом к большим **массивам данных**


## Что ИИ делает?



Упрощенный ответ

# Что есть ИИ?


## Что есть ИИ на самом деле?



Очень упрощенный ответ

ИИ — это **компьютерная программа**, располагающая большой **вычислительной мощностью**, гигантской **памятью** и доступом к большим **массивам данных**

## Что ИИ делает?



Упрощенный ответ

Любое действие ИИ — это решение определенной **задачи по оптимизации**, специально сформулированной по входным данным

**Ученые, внесшие основной вклад,  
и методы ИИ**

# Ученые, внесшие основной вклад, и методы ИИ




Середина XVIII века

**Ньютон и Лейбниц**

Общие методы  
оптимизации


Методы первого  
и второго порядка



Начало XIX века

**Гаусс и Лежандр**

Метод наименьших  
квадратов



Около 1920

**Фишер**

Метод максимума  
правдоподобия как  
универсальное решение  
задачи по тренировке  
модели

# Метод максимума правдоподобия

Пусть  $L(v)$  — случайная функция (потери, эмпирический риск, функция правдоподобия, ...).

Рассмотрим:

$$\underbrace{\tilde{v} = \operatorname{argmin}_v L(v)}_{\text{trained}} ; \quad \underbrace{v^* = \operatorname{argmin}_v \mathbb{E}L(v)}_{\text{truth}} ;$$

Этот подход включает основные процедуры трейнинга:


MLE, LSE, LAD, Minimum Contrast, ...

**Математическая проблема:** описать  $\tilde{v} - v^*$  (ошибка трейнинга) и  $L(\tilde{v}) - L(v^*)$  (эксцесс).

**Теория возмущенной оптимизации:**  $L(v)$  — это возмущение  $f(v) = \mathbb{E}L(v)$  **случайной компонентой**

$$\zeta(v) = L(v) - \mathbb{E}L(v)$$

# Особенности современной теории обучения



Большие объемы данных

01

Очень сложные модели  
с огромным числом параметров

02

Важна вычислимость решений (за короткое  
время) и масштабируемость методов.  
Время вычислений растет линейно  
с размерностью

03

# Классическая асимптотика (Фишер)

Если **размерность модели** (число параметров  $p$ ) фиксированна, а **объем выборки** растет к бесконечности ( $n \rightarrow \infty$ ), то для ОМП  $\tilde{v}$  верно:

$$\sqrt{n}(\tilde{v} - v) \xrightarrow{w} \mathcal{N}(0, F_v),$$

См. любой учебник по статистике, например:

- Боровков Л. Л. Математическая статистика. 1984.
- Lehmann and Romano. Testing statistical hypotheses. 2006.
- Van der Vaart. Asymptotic statistics. 2000.




# Современные приложения: новые феномены




- Огромная размерность моделей  $p \gg n$ , проблема переобучаемости, необходимость регуляризации  
[Cheng and Montanari, 2022]
- Случайный план и плохо обусловленная матрица Фишера  
[Bartlett et al., 2020, Montanari et al., 2025, Kuchelmeister and van de Geer, 2024]
- Смещение, вызванное случайным планом и высокой размерностью задачи. Теория Фишера неприменима  
[Sur and Candès, 2019, Candès and Sur, 2020]
- Требуются новые подходы, позволяющие получить гарантии точности для конечных объемов выборок и высокой размерности модели  
[Cheng and Montanari, 2022]

# Новые феномены


в простейшей линейной модели



Феномен «двойного спуска» (double descent).  
Фазовый переход в переобучаемости  
[Bach, 2024]



Преодоление переобучаемости (benign overfitting).  
Перепараметризация может быть даже полезной.  
Оптимальная обучаемость и отличное качество предсказания  
[Bartlett et al., 2020, Montanari et al., 2025,  
Kuchelmeister and van de Geer, 2024]



Методы оптимизации второго порядка неприменимы  
в практических постановках с плохо обусловленным Гессианом.  
Методы первого порядка + «ранняя остановка» хорошо работают  
[Wu et al., 2025].

Методы нулевого порядка (без использования производных)  
все более популярны

# Математические дисциплины



Теоретические выводы даже для простейших моделей в **неоклассической постановке** требуют развития математических дисциплин, таких как:

- **Возмущенная оптимизация**
- Теория **случайных матриц**
- Неравенства **больших уклонений** для случайных тензоров
- Методы **регуляризации** для нелинейных обратных задач

# Некоторые законы в современном звучании

Закон Фишера  $p \ll n$  (для обучения нужно много наблюдений на каждый параметр).


Уточненная версия закона Фишера: важны **эффективная размерность**  $\mathfrak{p}$   
Место для уравнения.и **эффективный объем выборки**  $\mathbb{N}$  matter.

Нео-Фишер:  $\mathfrak{p} \ll \mathbb{N}$ .

**Эффективная размерность**  $\mathfrak{p}$  может контролироваться путем подбора **пенализации** или методами **редукции модели**.

**Эффективный объем выборки**  $\mathbb{N}$  определяется нормой и обусловленностью матрицы Фишера  $\mathbb{F}$ . Неформально это объем имеющейся информации.

# Distribution of the leading term and the remainder

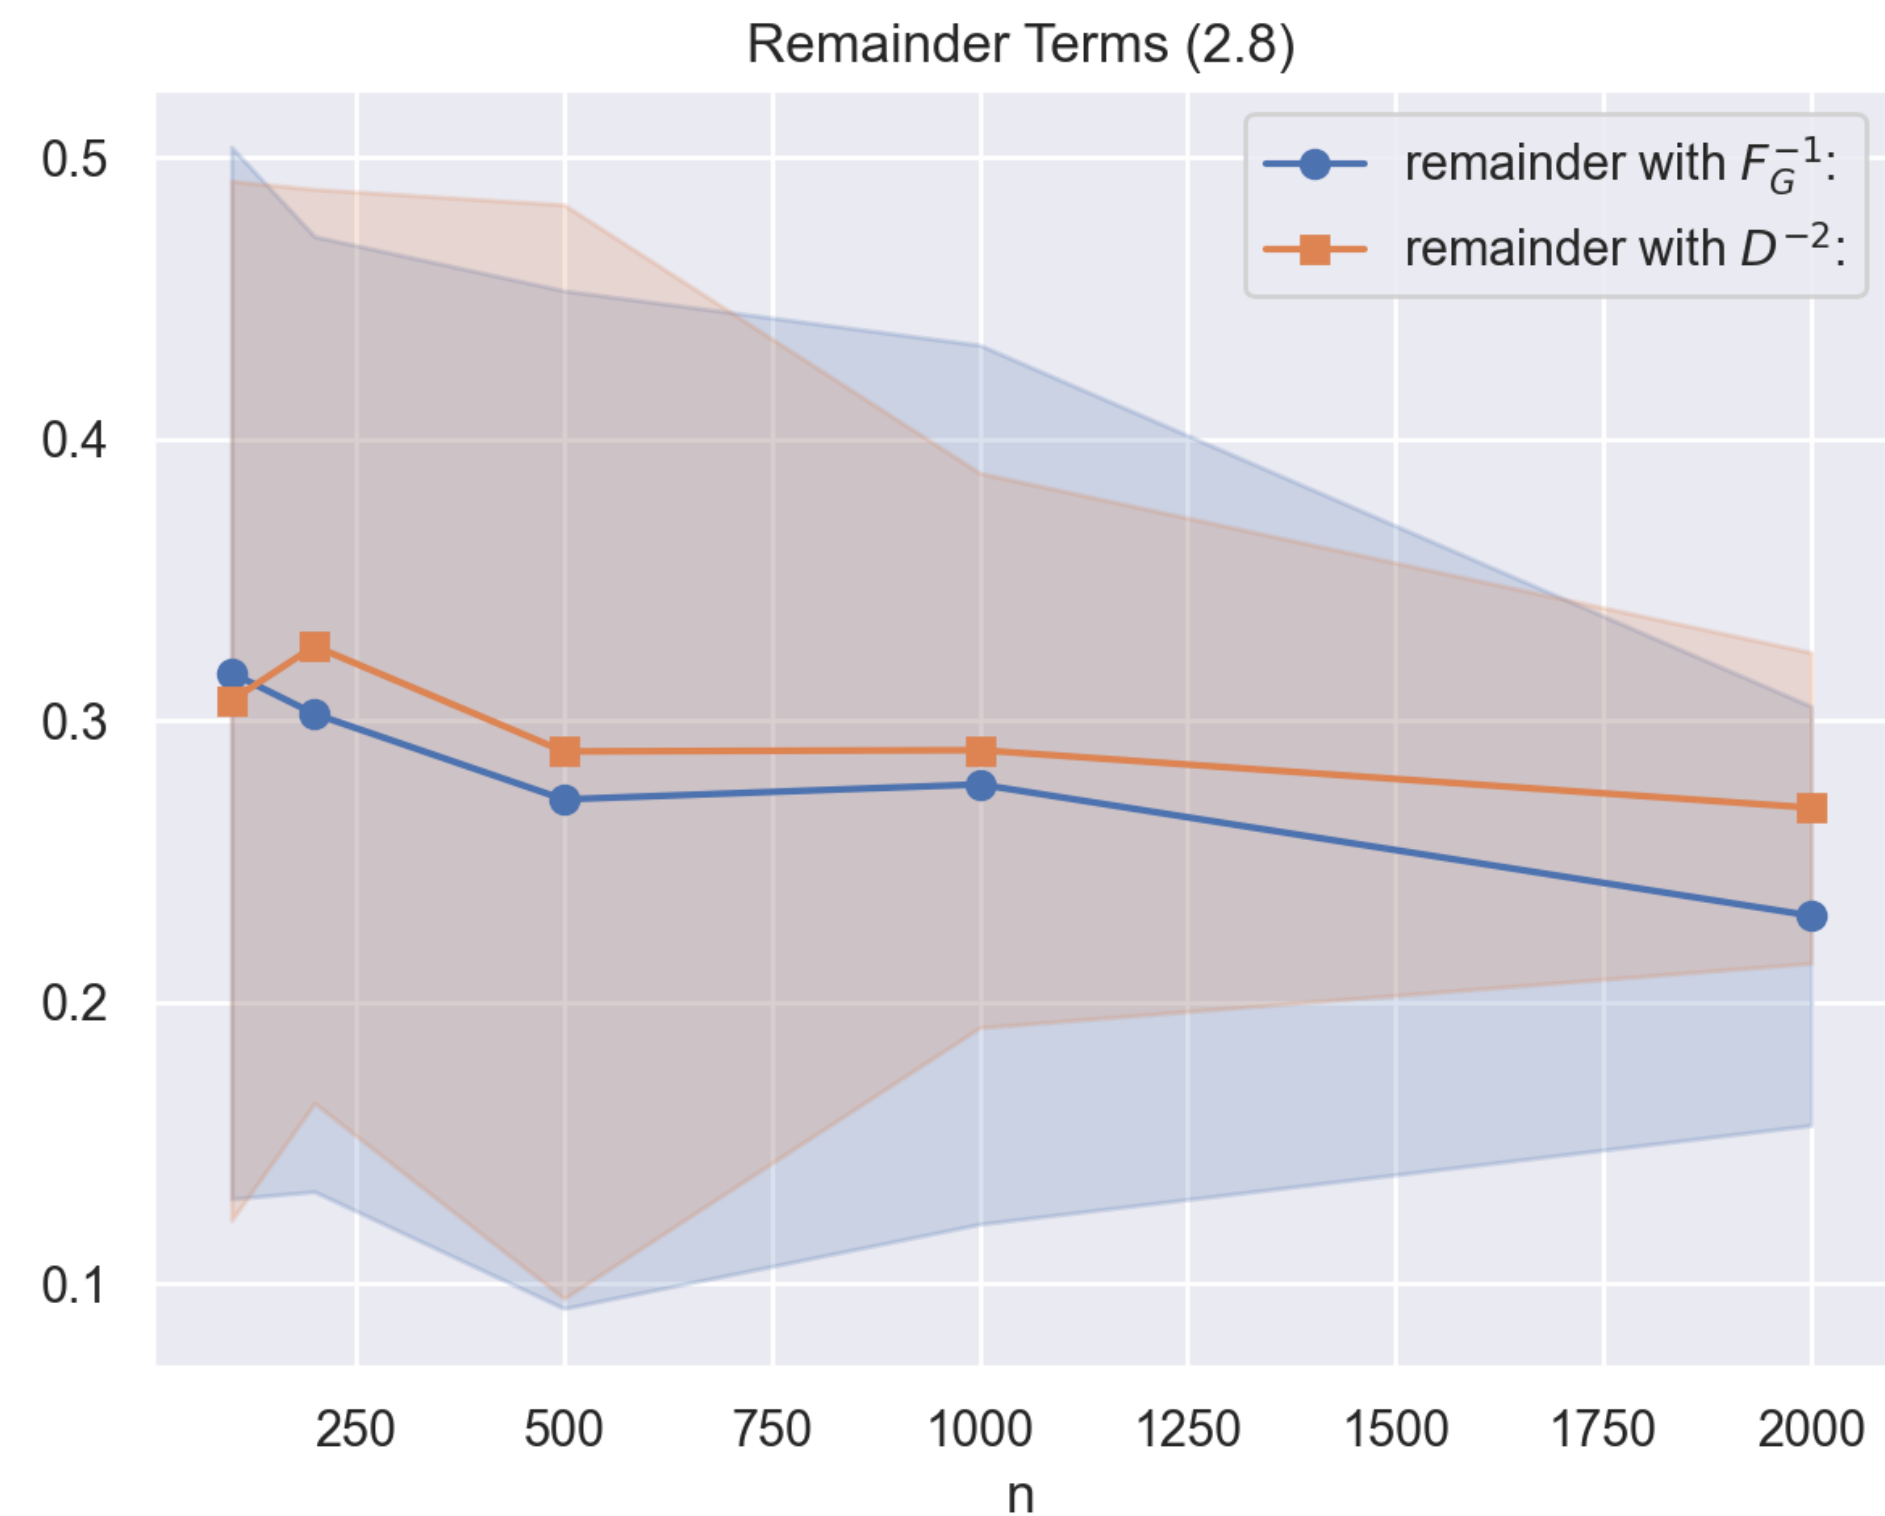
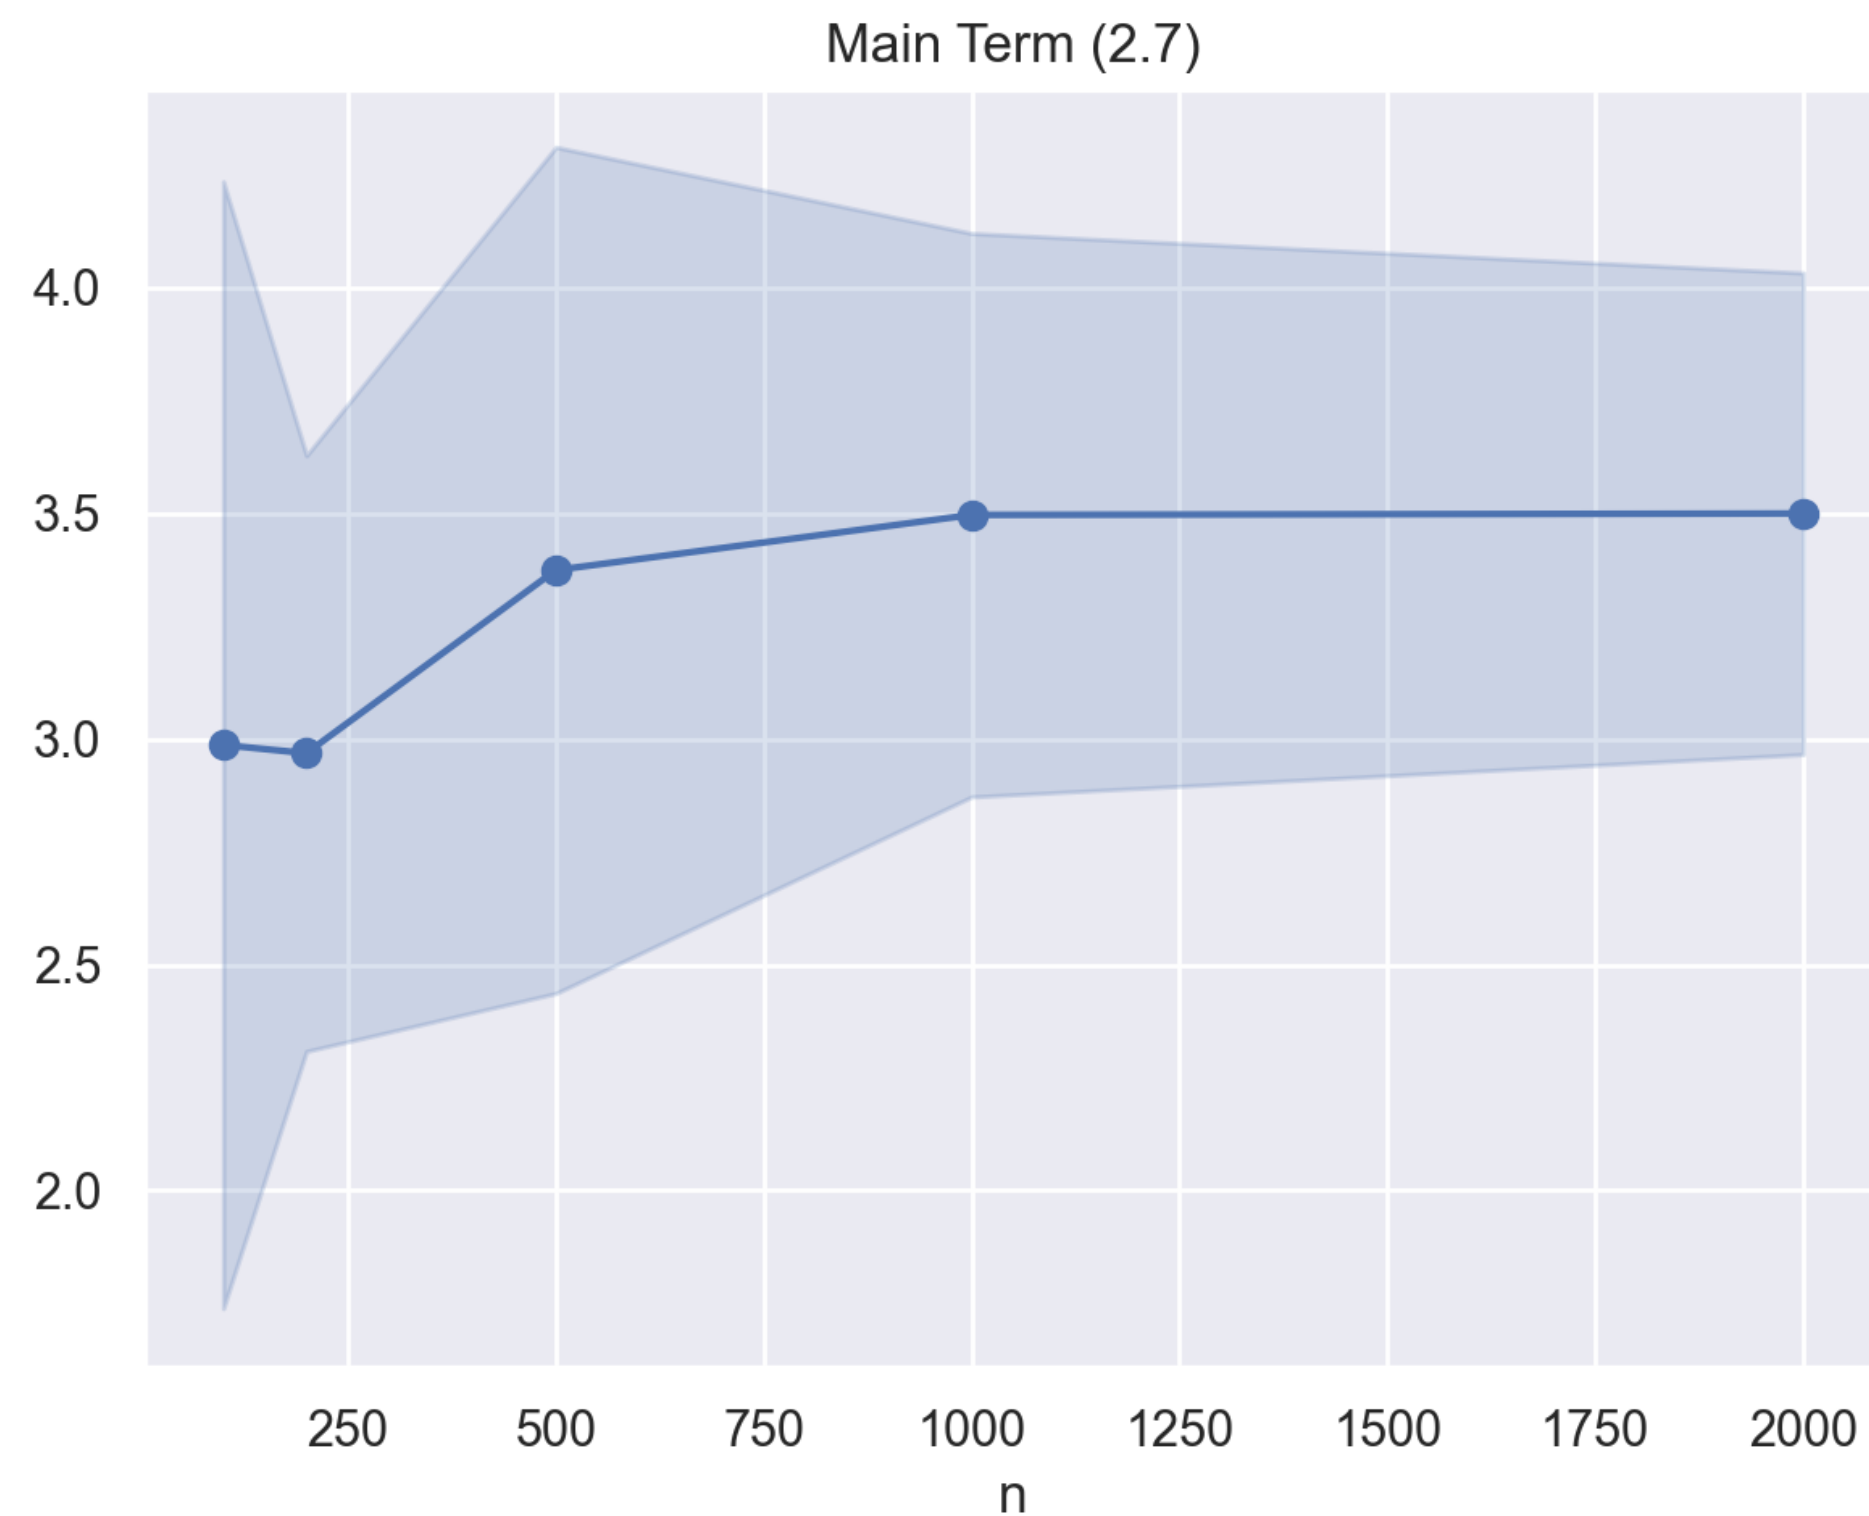


Distribution of the leading term and the remainder for  $n = 100$ .

Left: ошибка тренировки  $\|F_G^{-1}\nabla\zeta\|_\infty$  и  $\|D^{-2}\nabla\zeta\|_\infty$ . Right: ошибка после коррекции Фишера  $\|\tilde{v} - v^* + F^{-1}\nabla\zeta\|_\infty$  и  $\|\tilde{v} - v^* + D^{-2}\nabla\zeta\|_\infty$  для  $n = 100$ .

Ошибка справа примерно в 10 раз меньше ошибки слева: иллюстрирует качество работы математического закона.

# Результаты для $n \in \{100, 200, 500, 1000, 2000\}$



Comparison of the leading term and the remainder for different  $n$ .

# DNN

Данные  $(Y_i, X_i)$ , где  $Y_i$  — отклик (метка) и регрессор  $X_i \in \mathbb{R}^d$ .

**Цель:** построить сеть с малой ошибкой предсказания  $Y_i - m(X_i)$ .

**Двухуровневая (Shallow) сеть:**  $\mathbb{X} = \sigma(WX)$ .

**Глубинная сеть (DNN):**  $\mathbb{X} = \mathbb{X}^{(K)} = DNN(X) \in \mathbb{R}^M$

$$DNN(X) = \sigma \left( W^{(K)} \sigma \left( W^{(K-1)} \dots \sigma \left( W^{(1)} X \right) \right) \right),$$

где  $M = M^{(K)}$  — число узлов в последнем слое,  $W^{(k)} = (w_{mj})$  —  $M_k \times M_{k-1}$  — матрица весов со строками  $W_m^{(k)}$ ,  $\sigma$  — функция активации.

**Предсказание** на основе **линейной регрессии** на выход последнего слоя  $\mathbb{X}$ :

$$m(X_i) = \mathbb{X}_i^T \beta = \underbrace{\sigma(WX_i)^T}_{\text{shallow}} \beta$$

# Обучение глубинных сетей

Двухуровневая (**shallow**) модель:  $DNN(X_i|W) = \sigma(WX_i)$ .

Глубинная (**deep**) модель:  $W = (W^{(1)}, \dots, W^{(K)})$ .

$$DNN(X|W) = \sigma \left( W^{(K)} \sigma \left( W^{(K-1)} \dots \sigma \left( W^{(1)} X \right) \right) \right),$$

Метод обучения (ОМП):

$$m(X_i|W, \beta) = DNN(X_i|W)^T \beta$$

$$L(W, \beta) = \sum_{i=1}^n |Y_i - m(X_i|W, \beta)|^2$$

$$(\widehat{W}, \widehat{\beta}) = \operatorname{argmin}_{W, \beta} L(W, \beta)$$

**Сложность:** задача невыпуклая, неидентифицируемая, перепараметризованная.

# Some statistical literature on DNN regression

- [Schmidt-Hieber, 2020]. Nonparametric regression using deep neural networks with ReLU activation function, Kolmogorov-Arnold representation.
- [Zuowei Shen et al., 2020], Deep Network Approximation Characterized by Number of Neurons.
- [Fan et al., 2024], How do noise tails impact on deep ReLU networks? polynomial noise, tails, Huber, DNN approximation.
- [Kohler and Krzyzak, 2022], Analysis of the rate of convergence of an overparametrized deep neural network estimate learned by gradient descent.
- [Shen et al., 2022], Approximation with CNNs in Sobolev Space: with Applications to Classification.
- [Liu et al., 2022], Benefits of Overparameterized Convolutional Residual Networks: Function Approximation under Smoothness Constraint.
- [Simionescu-Badea, 2022], Analysis of the rate of convergence of fully connected deep neural network regression estimates with smooth activation.

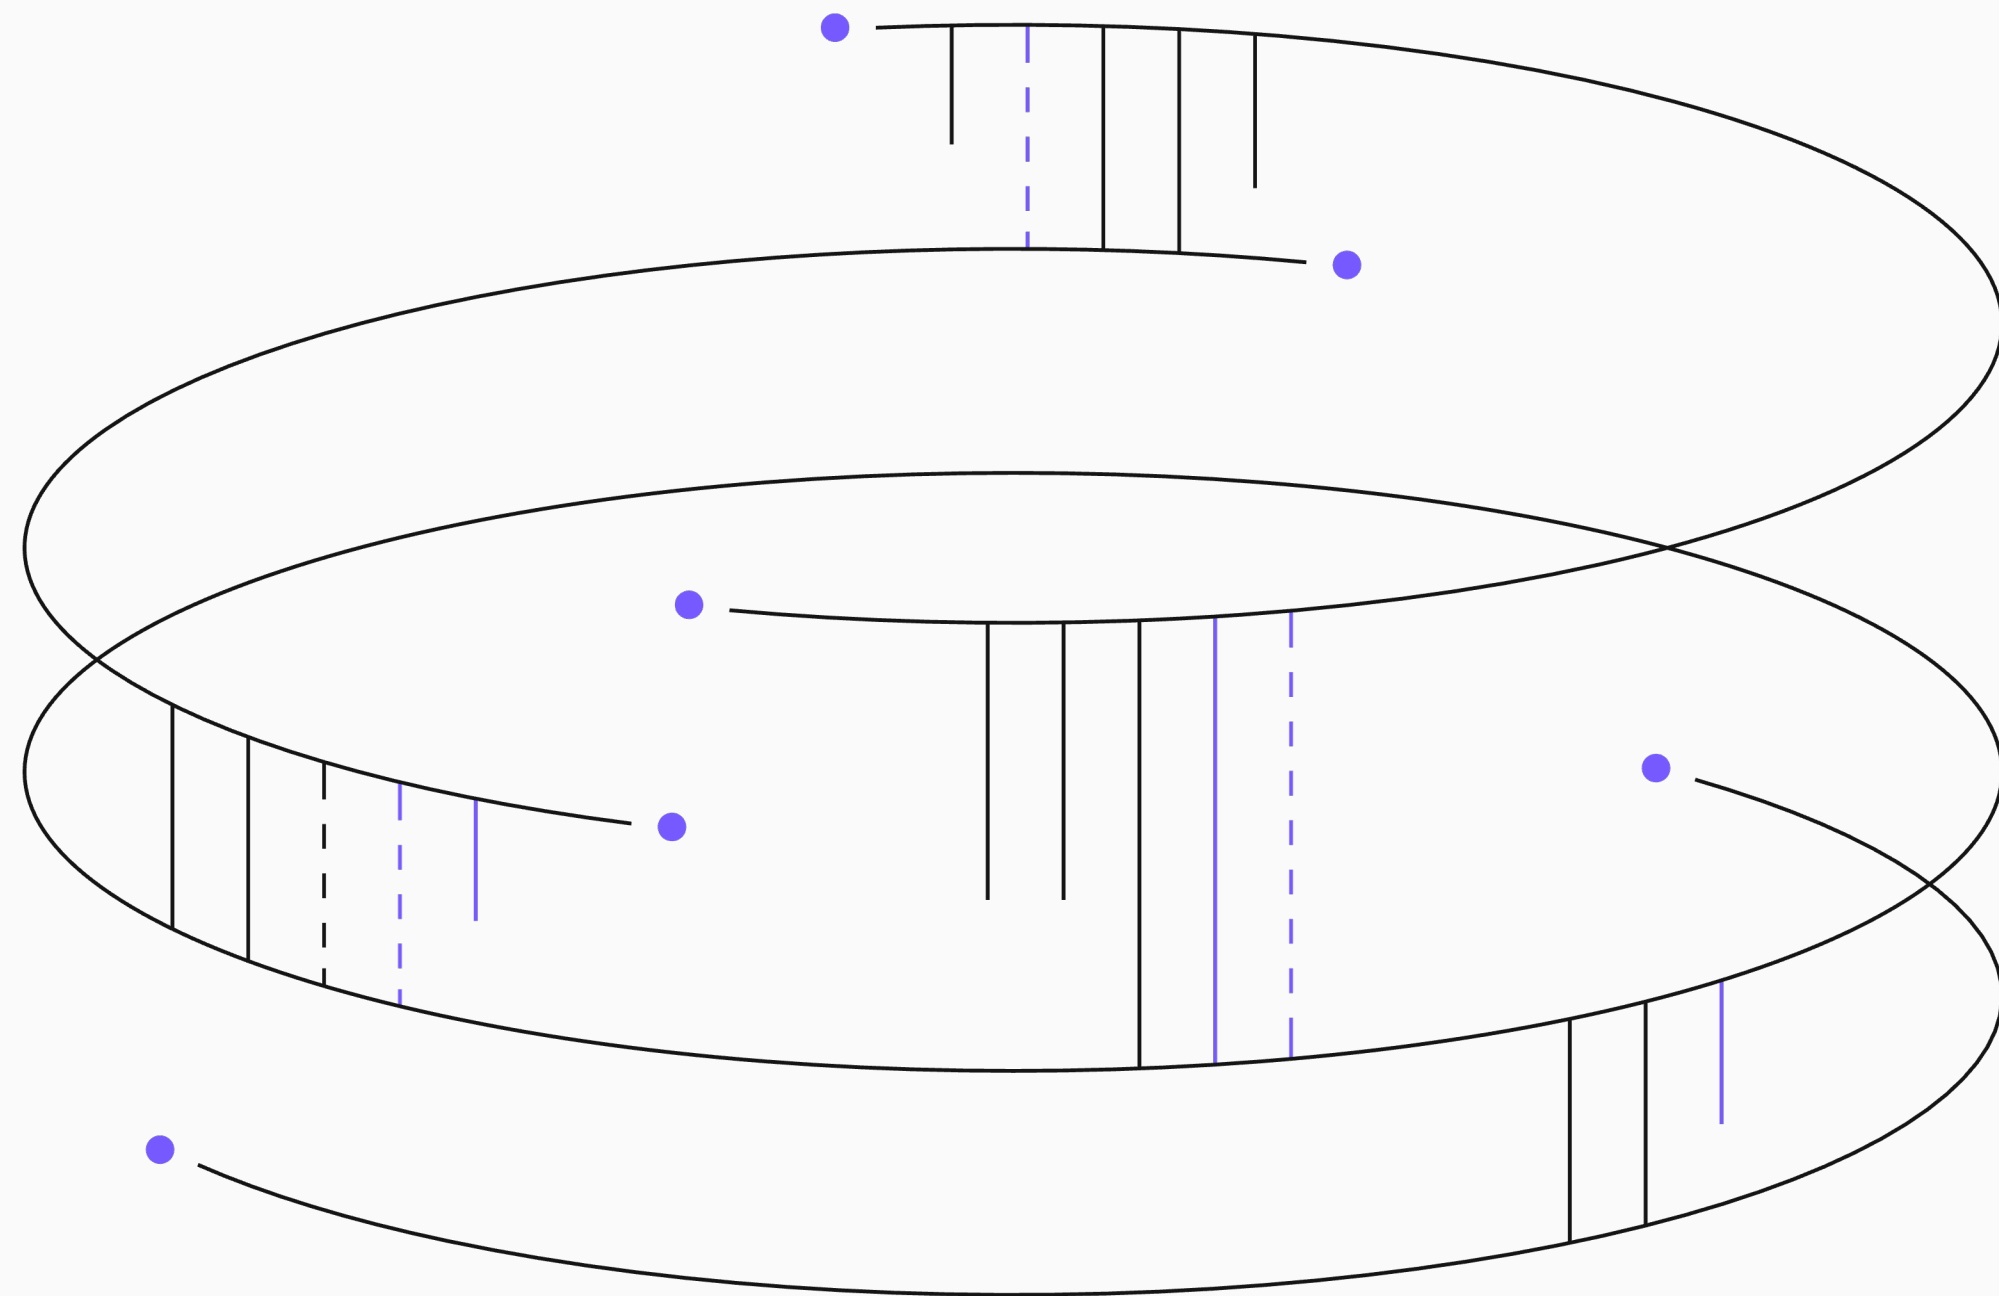


# Manifold regression

- [Chen et al., 2019], Efficient Approximation of Deep ReLU Networks for Functions on Low Dimensional Manifolds.
- [Kohler et al., 2019], Estimation of a Function of Low Local Dimensionality by DNN.
- [Jiao et al., 2021], Deep Nonparametric Regression on Approximately Low-dim Manifolds.
- [Liu et al., 2021], Besov Function Approximation ...on Low-Dim Manifolds ...
- [Cloninger and Klock, 2021], A deep network construction that adapts to intrinsic dimensionality beyond the domain.
- [Zhang et al., 2023], Effective Minkowski Dimension of Deep Nonparametric Regression: Function Approximation and Statistical Theories.
- [Shen et al., 2023], RePU DNN, manifolds, Differentiable Neural Networks with RePU Activation: with Applications...
- [Jiao et al., 2023], Deep nonparametric regression on approximate manifolds.




# Проклятие размерности



Размерность?


# Проклятие размерности



Размерность?

Число регрессоров  $d$ ?

# Проклятие размерности




Размерность?

Число регрессоров  $d$ ?

Или

# Проклятие размерности



Размерность?

Число регрессоров  $d$ ?

Или


Число параметров  $p$  модели?

Совпадение для линейных моделей

# Благословение размерности: идея

Число параметров  $p$  не важно  
и не входит в оценки точности

А что важно?




# Благословение размерности: идея

Число параметров  $p$  не важно  
и не входит в оценки точности

## А что важно?

- Эффективная размерность  $p$
- Геометрические свойства (такие как **строгая выпуклость**) целевой функции




# Благословение размерности: идея

Число параметров  $p$  не важно  
и не входит в оценки точности

## А что важно?

- Эффективная размерность  $\mathbb{P}$
- Геометрические свойства (такие как **строгая выпуклость**) целевой функции


Подходящее **расширение** модели может быть полезным  
и может улучшить геометрические свойства целевой функции  
без значительного увеличения **эффективной размерности**



# Снижение размерности многомерных распределений данных


Высокая размерность —  
проклятие для моделей данных.

Например, для генеративных  
моделей нужно семплировать  
из таких распределений.




## Наблюдение 1

Любое многомерное облако данных выглядит как шарик (из нормального распределения). Этот нетривиальный факт может быть обоснован применением центральной предельной теоремы в асимптотике растущей Размерности.



## Наблюдение 2

Нормальное распределение неинформативно и отражает многомерный «шум».



## Наблюдение 3

Информативная негауссовская компонента распределения сосредоточена в подпространстве малой размерности.

## Идея снижения размерности:

восстановить по данным информативное подпространство и использовать для моделирования (предсказания).


# Моделирование многомерных распределений

Информативная модель должна быть **мультимодальной**


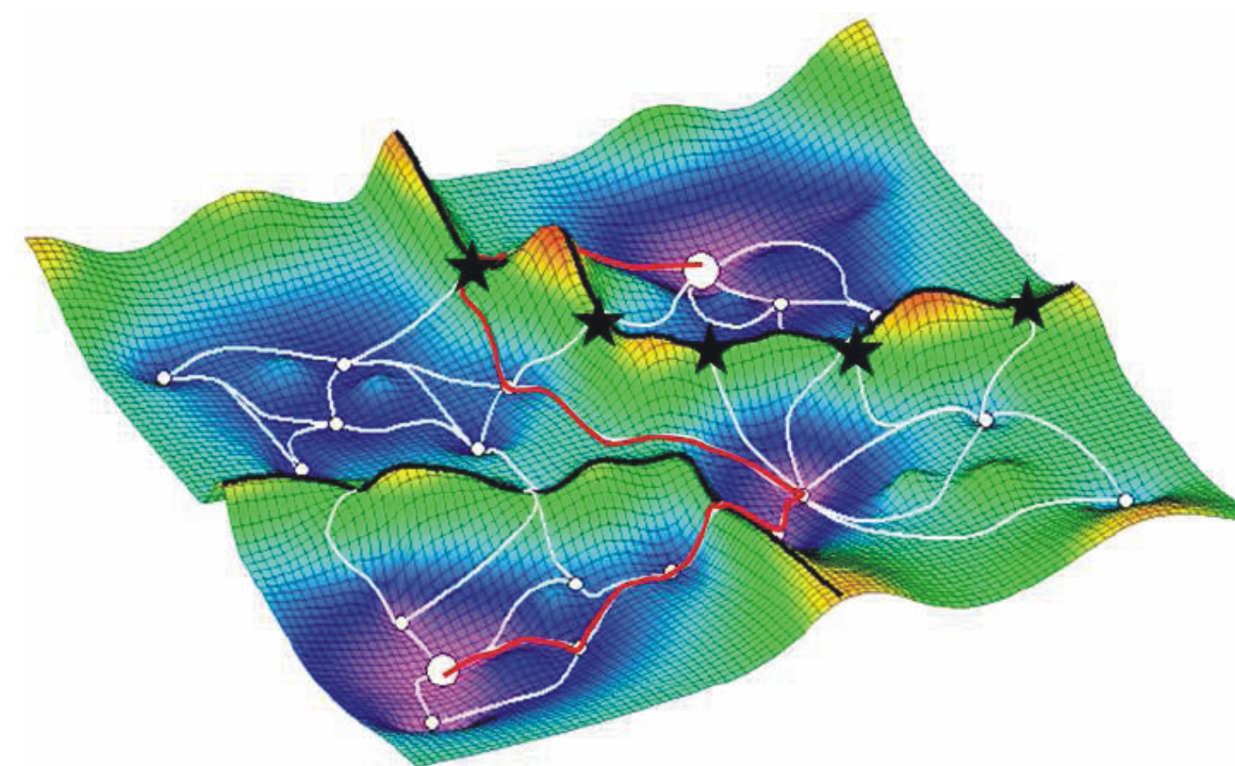

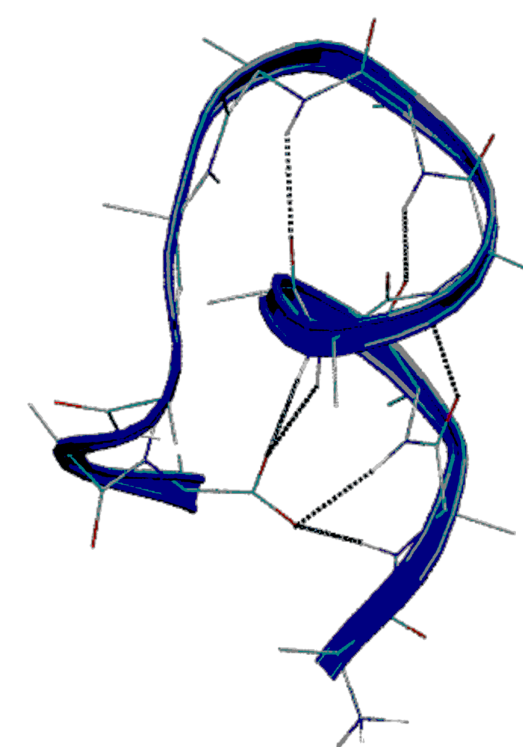

Типичный пример — **гауссовские смеси**

Общая (гибкая, быстрая, хорошо настраиваемая, масштабируемая) модель многомерного распределения:

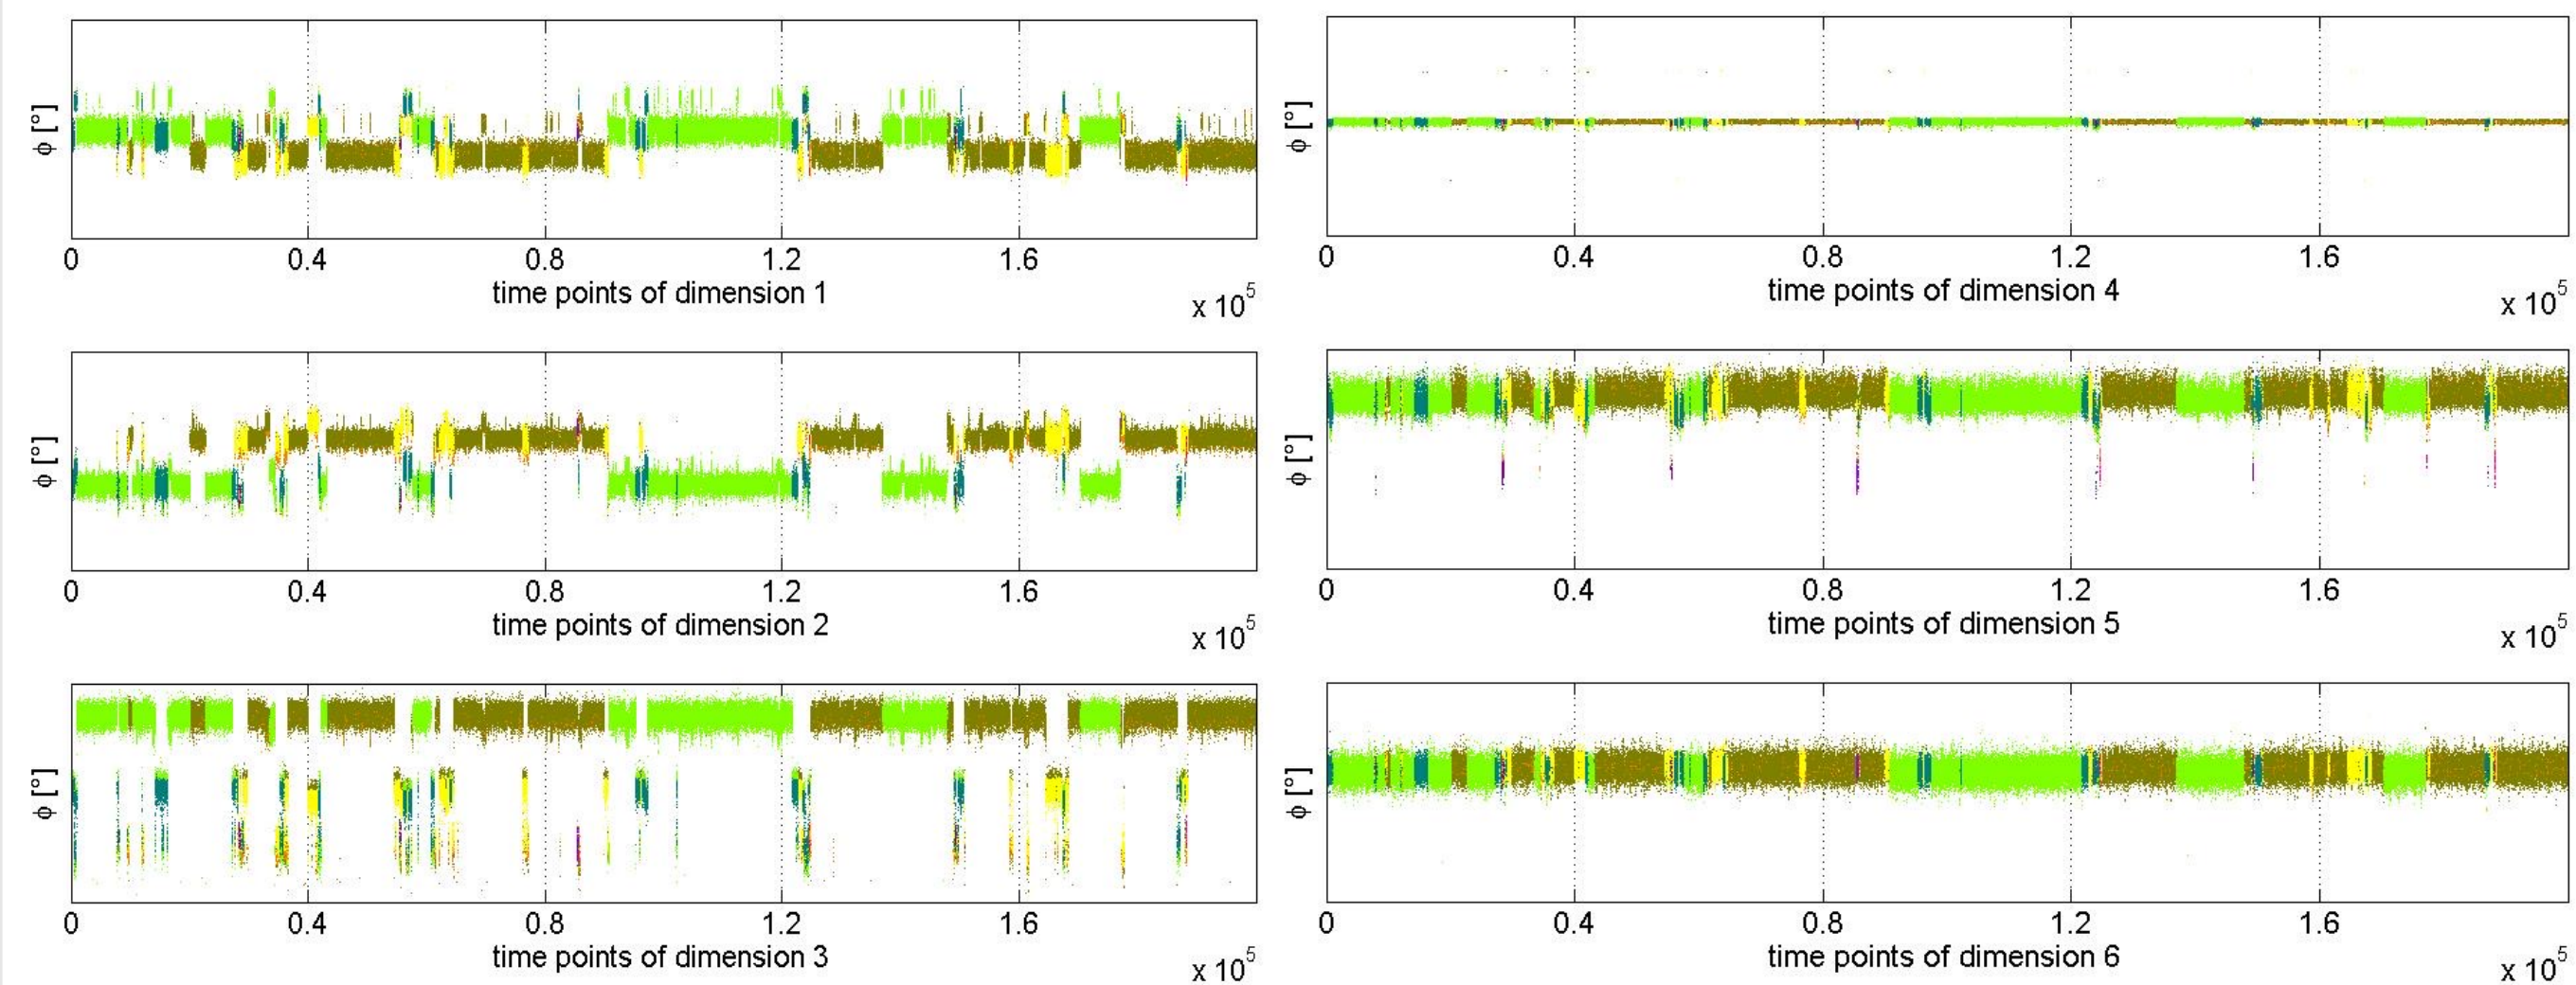
**Маломерная гауссовская смесь + Многомерный гауссовский шум**





# Моделирование протеинов



# Моделирование протеинов



# Моделирование протеинов



Понимание математических законов важно для моделей ИИ, определения их надежности

Основные понятия в формулировках — **эффективная размерность** и **эффективный объем выборки**

Методы и идеи **снижения размерности** могут быть эффективно использованы в современных моделях ИИ

Расширение параметрического пространства может быть полезным (**благословление размерности**), при условии что эффективная размерность не «взрывается»



**Выводы  
и заключения**

# References I

- Al-Ghattas, O., Chen, J., and Sanz-Alonso, D. (2025). Sharp concentration of simple random tensors. [arxiv.org/abs/2502.16916](https://arxiv.org/abs/2502.16916).
- Bach, F. (2024). High-dimensional analysis of double descent for linear regression with random projections. *SIAM Journal on Mathematics of Data Science*, 6(1):26—50.
- Bartlett, P. L., Long, P. M., Lugosi, G., and Tsigler, A. (2020). Benign overfitting in linear regression. *Proceedings of the National Academy of Sciences*, 117(48):30063—30070.
- Candès, E. J. and Sur, P. (2020). The phase transition for the existence of the maximum likelihood estimate in high-dimensional logistic regression. *The Annals of Statistics*, 48(1):27—42.
- Chen, M., Jiang, H., Liao, W., and Zhao, T. (2019). Efficient approximation of deep relu networks for functions on low dimensional manifolds. *ArXiv*, abs/1908.01842:null.
- Cheng, C. and Montanari, A. (2022). Dimension free ridge regression. <https://arxiv.org/abs/2210.08571>.
- Cloninger, A. and Klock, T. (2021). A deep network construction that adapts to intrinsic dimensionality beyond the domain. *Neural Networks*, 141:404—419.

# References II

- Fan, J., Gu, Y., and Zhou, W.-X. (2024).  
How do noise tails impact on deep ReLU networks?  
The Annals of Statistics, 52(4):1845—1871.
- Jiao, Y., Shen, G., Lin, Y., and Huang, J. (2021).  
Deep nonparametric regression on approximately low-dimensional manifolds.  
arXiv: Statistics Theory, page null.
- Jiao, Y., Shen, G., Lin, Y., and Huang, J. (2023).  
Deep nonparametric regression on approximate manifolds: Nonasymptotic error bounds with polynomial prefactors.  
The Annals of Statistics, 51:691—716.
- Kohler, M. and Krzyżak, A. (2022).  
Analysis of the rate of convergence of an over-parametrized deep neural network estimate learned by gradient descent.
- Kohler, M., Krzyżak, A., and Langer, S. (2019).  
Estimation of a function of low local dimensionality by deep neural networks.  
IEEE Transactions on Information Theory, 68:4032—4042.
- Koltchinskii, V. and Lounici, K. (2017).  
Concentration inequalities and moment bounds for sample covariance operators.  
Bernoulli, 23(1):110—133.
- Kuchelmeister, F. and van de Geer, S. (2024).  
Finite sample rates for logistic regression with small noise or few samples.  
Sankhya A.

# References III

- Liu, H., Chen, M., Er, S., Liao, W., Zhang, T.-M., and Zhao, T. (2022).  
Benefits of overparameterized convolutional residual networks: Function approximation under smoothness constraint.  
ArXiv, abs/2206.04569:null.
- Liu, H., Chen, M., Zhao, T., and Liao, W. (2021).  
Besov function approximation and binary classification on low-dimensional manifolds using convolutional residual networks.
- Montanari, A., Ruan, F., Sohn, Y., and Yan, J. (2025).  
The generalization error of max-margin linear classifiers: Benign overfitting and high dimensional asymptotics in the overparametrized regime.  
The Annals of Statistics, 53(2):822—853.
- Nesterov, Y. and Nemirovskii, A. (1994).  
Interior-Point Polynomial Algorithms in Convex Programming.  
Society for Industrial and Applied Mathematics.
- Noskov, F., Puchkin, N., and Spokoiny, V. (2025).  
Dimension-free bounds in high-dimensional linear regression via error-in-operator approach.  
arxiv.org/abs/2502.15437.
- Ostrovskii, D. M. and Bach, F. (2021).  
Finite-sample analysis of M-estimators using self-concordance.  
Electronic Journal of Statistics, 15(1):326—391.
- Schmidt-Hieber, J. (2020).  
Nonparametric regression using deep neural networks with ReLU activation function.  
The Annals of Statistics, 48(4):1875—1897.

# References IV

- Shen, G., Jiao, Y., Lin, Y., and Huang, J. (2022).  
Approximation with cnns in sobolev space: with applications to classification.
- Shen, G., Jiao, Y., Lin, Y., and Huang, J. (2023).  
Differentiable neural networks with repu activation: with applications to score estimation and isotonic regression.  
ArXiv, abs/2305.00608:null.
- Simionescu-Badea, C. (2022).  
Analysis of the rate of convergence of fully connected deep neural network regression estimates with smooth activation function.
- Spokoiny, V. (2025a).  
Marginal minimization and sup-norm expansions in perturbed optimization.  
arxiv.org/2505.02562.
- Spokoiny, V. (2025b).  
Sharp bounds in perturbed smooth optimization.  
arxiv.org/2504.11834.
- Sur, P. and Candès, E. J. (2019).  
A modern maximum-likelihood theory for high-dimensional logistic regression.  
Proceedings of the National Academy of Sciences, 116(29):14516—14525.
- Tropp, J. A. (2015).  
An introduction to matrix concentration inequalities.  
Foundations and Trends in Machine Learning, 8(1-2):1—230.

# References V

- Vershynin, R. (2018).  
High-Dimensional Probability: An Introduction with Applications in Data Science.  
Number 47 in Cambridge Series in Statistical and Probabilistic Mathematics. Cambridge University Press.
- Wu, J., Marion, P., and Bartlett, P. (2025).  
Large stepsizes accelerate gradient descent for regularized logistic regression.  
arXiv preprint arXiv:2506.02336.
- Zhang, Z., Chen, M., Wang, M., Liao, W., and Zhao, T. (2023).  
Effective minkowski dimension of deep nonparametric regression: Function approximation and statistical theories.  
ArXiv, abs/2306.14859:null.
- Zhivotovskiy, N. (2024).  
Dimension-free bounds for sums of independent matrices and simple tensors via the variational principle.  
Electronic Journal of Probability, 29(none):1—28.
- Zuowei Shen, Z. S., Haizhao Yang, H. Y., and Shijun Zhang, S. Z. (2020).  
Deep network approximation characterized by number of neurons.  
Communications in Computational Physics, 28(5):1768—1811.



**ЦЕНТРАЛЬНЫЙ  
УНИВЕРСИТЕТ**

**Спасибо  
за внимание!**

