



# Современные методы вычислительной физики


Суррогатные модели, PINN и машинно-обученные  
межатомные потенциалы

---

Лю Шисян

Кафедра теплофизики (Э6)  
МГТУ им. Н.Э. Баумана  
Москва / 2026

# Место этой лекции в курсе



## Связь с предыдущей лекцией

На лекции 7 мы разобрали, как устроена и обучается нейронная сеть. Теперь рассмотрим, где именно машинное обучение может входить в физическую модель.

От алгоритма нейросети — к задачам вычислительной физики.

# План

---

- 1 Суррогатные модели
- 2 Физически-информированные нейронные сети
- 3 Машинно-обученные межатомные потенциалы
- 4 Практика и итоги

ТОС

# 1

## Суррогатные модели

---

# Когда нужен суррогат?

## Традиционный расчёт

Для каждого нового набора параметров нужно заново запускать

FEM / MC / DFT / эксперимент.

Это может занимать минуты, часы или значительно больше.

Например:


$$(T, L, \eta) \longrightarrow \text{MC} \longrightarrow \kappa.$$

## Суррогатная модель

Сначала строим ограниченный набор точных данных, а затем обучаем модель приближать отображение


$$\mathbf{x} \longrightarrow \mathbf{y}.$$

После обучения новый прогноз выполняется очень быстро.



**Суррогат заменяет повторяющийся дорогой расчёт, но учится на его результатах.**

# Как строится суррогатная модель?



## Входы

Геометрия, температура, состав, параметры режима:

$$\mathbf{x} = (T, L, W, \eta, \dots).$$

## Выход

Физическое свойство:

$$\mathbf{y} = (\kappa, C_v, \dots).$$

## Важно

Качество суррогата определяется не только архитектурой сети, но прежде всего качеством и покрытием обучающих данных.

# Пример: прогноз теплопроводности

В учебном примере используются два входа:

$$T, L$$


и один выход:

$$\kappa.$$

## Архитектура

$$2 \rightarrow 32 \rightarrow 32 \rightarrow 1$$

Два скрытых слоя с ReLU, задача регрессии, loss — MSE.



## Что даёт модель?


После обучения можно быстро оценивать

$$\kappa(T, L)$$

для новых точек внутри изученного диапазона.

**Суррогатная модель аппроксимирует уже известное отображение «условия → свойство».**

# Интерполяция и экстраполяция



## Интерполяция

Новая точка находится внутри области, покрытой обучающими примерами.

## Экстраполяция

Модель используется за пределами известных данных.  
Здесь ошибка может резко возрасти.

Перед использованием surrogate model нужно знать область применимости обучающего набора.

# 2

## Физически-информированные нейронные сети

---

# От обычной нейросети к PINN

## Обычная нейросеть

Учится на парах данных:

$$\mathbf{x}_i \rightarrow \mathbf{y}_i.$$

Физический закон явно не используется:


$$\mathcal{L} = \mathcal{L}_{\text{data}}.$$

## Physics-Informed NN

Кроме данных, известны уравнения и условия задачи.

Они добавляются в loss:

$$\mathcal{L} = \mathcal{L}_{\text{data}} + \mathcal{L}_{\text{physics}}.$$



**PINN обучается не только «похожести на данные», но и выполнению физического закона.**

# Пример: одномерная теплопроводность

Рассмотрим задачу

$$\frac{\partial T}{\partial t} = \alpha \frac{\partial^2 T}{\partial x^2}, \quad x \in (0, L), \quad t > 0.$$

## Начальное условие

$$T(x, 0) = T_0(x).$$


Оно задаёт начальное распределение температуры.

## Граничные условия

Например,

$$T(0, t) = T_L, \quad T(L, t) = T_R.$$

Они задают поведение на границах области.




# Почему PINN может вычислять производные?

Нейросеть задаёт непрерывную функцию

$$T_{\theta} = T_{\theta}(x, t).$$

Благодаря автоматическому дифференцированию можно получить

$$\frac{\partial T_{\theta}}{\partial t}, \quad \frac{\partial T_{\theta}}{\partial x}, \quad \frac{\partial^2 T_{\theta}}{\partial x^2}.$$



**PINN превращает дифференциальное уравнение в функцию потерь.**

# Как строится функция потерь PINN?

Для теплопроводности определим residual

$$r(x, t) = T_t - \alpha T_{xx}.$$

## Физика внутри области

$$\mathcal{L}_{\text{PDE}} = \frac{1}{N_f} \sum_{i=1}^{N_f} |r(x_i, t_i)|^2.$$

## Начальное условие

$$\mathcal{L}_{\text{IC}} = \frac{1}{N_i} \sum_i |T_\theta(x_i, 0) - T_0(x_i)|^2.$$

## Граничные условия

$$\mathcal{L}_{\text{BC}} = \frac{1}{N_b} \sum_i |T_\theta(x_i^b, t_i) - T_b|^2.$$

## Дополнительные данные

При наличии измерений можно добавить

$$\mathcal{L}_{\text{data}}.$$

$$\mathcal{L} = \lambda_f \mathcal{L}_{\text{PDE}} + \lambda_b \mathcal{L}_{\text{BC}} + \lambda_i \mathcal{L}_{\text{IC}} + \lambda_d \mathcal{L}_{\text{data}}$$

# Преимущества и ограничения PINN

## Преимущества

- физика входит прямо в процесс обучения;
- можно использовать редкие или шумные данные;
- легко включать неизвестные физические параметры;
- решение задаётся непрерывной функцией  $T_{\theta}(x, t)$ .

## Ограничения

- обучение может быть трудным и медленным;
- разные компоненты loss имеют разные масштабы;
- сложны stiff, multiscale и высокочастотные задачи;
- сходимость оптимизатора не эквивалентна автоматически высокой физической точности.

**PINN полезны там, где данные и физические ограничения нужно учитывать одновременно.**

# 3

## Машинно-обученные меж- атомные потенциалы

---

# Почему молекулярной динамике нужен потенциал?

Движение атомов определяется уравнением Ньютона:

$$m_i \ddot{\mathbf{R}}_i = \mathbf{F}_i.$$

Но силы связаны с потенциальной энергией:


$$\mathbf{F}_i = -\frac{\partial E}{\partial \mathbf{R}_i}.$$

Следовательно, ключевой объект атомистического моделирования —

$$E(\mathbf{R}_1, \mathbf{R}_2, \dots, \mathbf{R}_N).$$



# DFT, эмпирические потенциалы и MLIP



## MLIP

- обучаются на reference data;
- существенно быстрее DFT;
- способны описывать сложные зависимости.

## Эмпирические потенциалы

- очень быстрые;
- аналитическая форма задаётся заранее;
- ограниченная гибкость.

## DFT

- высокая точность;
- используется для получения reference data;
- высокая вычислительная стоимость.

**MLIP стремятся сочетать точность reference data с эффективностью классического атомистического моделирования.**

# Как строится MLIP?



## Что должна содержать обучающая выборка?

Не одну равновесную структуру, а разнообразные конфигурации: температуры, деформации, дефекты, поверхности, неравновесные состояния и т.д.

## Главное ограничение

MLIP надёжен только в той области конфигурационного пространства, которая достаточно представлена в обучающих данных.

# Основные семейства MLIP

## Локальные дескрипторы

Сначала локальное окружение атома переводится в набор признаков.

Примеры:  
BPNN, GAP, MTP, ACE, NEP.

## Message passing

Информация передаётся между соседними атомами по графу.

Пример:  
SchNet и родственные модели.

## Эквивариантные модели

Архитектура явно учитывает преобразования вращения и геометрию.

Примеры:  
NequIP, MACE и др.

**Архитектуры различаются, но цель одна: точно приблизить поверхность потенциальной энергии.**

# NEP: от локального окружения к атомной энергии

Для атома  $i$  строится набор локальных дескрипторов

$$\mathbf{q}_i = (q_1^{(i)}, q_2^{(i)}, \dots, q_{N_{\text{des}}}^{(i)}).$$


Они подаются в нейронную сеть NEP:

$$\mathbf{q}_i \longrightarrow \mathbf{x}_i \longrightarrow U_i.$$

Здесь  $\mathbf{x}_i$  — выходы скрытого слоя после функции активации  $\tanh$ .

Полная энергия системы:

$$E = \sum_i U_i.$$



Силы определяются как

$$\mathbf{F}_i = -\frac{\partial E}{\partial \mathbf{R}_i}.$$

**Локальное окружение  $\rightarrow$  дескрипторы  $\rightarrow$  скрытые переменные  $x_\mu \rightarrow$  атомная энергия  $U_i$ .**

# NEP: что описывают локальные дескрипторы?

## Радиальная информация

Расстояния до соседних атомов:

$$q_n^i = \sum_{j \neq i} g_n(r_{ij}).$$


Описывает, **на каких расстояниях** находятся соседи.

## Угловая информация

Геометрия троек атомов:

$$q_{nl}^i = \sum_{j \neq i} \sum_{k \neq i} g_n(r_{ij}) g_n(r_{ik}) P_l(\cos \theta_{ijk}).$$

Описывает, **как расположены** соседи вокруг атома.



**Дескриптор — численное описание локального окружения атома.**

# NEP: обучение потенциала

Reference-данные обычно включают **энергию**, **силы** и **вириал / напряжения**.

Поэтому функция потерь записывается как

$$L = \lambda_E L_E + \lambda_F L_F + \lambda_V L_V + L_{\text{reg}}$$

## Энергия


$$E^{\text{NEP}} \leftrightarrow E^{\text{DFT}}$$

## Силы

$$\mathbf{F}^{\text{NEP}} \leftrightarrow \mathbf{F}^{\text{DFT}}$$

## Вириал

$$\mathbf{V}^{\text{NEP}} \leftrightarrow \mathbf{V}^{\text{DFT}}$$



**Обучение NEP — это согласование энергии, сил и вириала с reference-данными.**

# 4

## Практика и итоги

---

# Практика 1: обучаем surrogate для $\kappa(T, L)$

## Учебная задача

Сгенерировать данные

$$(T, L) \rightarrow \kappa,$$

разделить их на train/test и обучить  
небольшую сеть регрессии.

## Модель

$$2 \rightarrow 32 \rightarrow 32 \rightarrow 1$$

ReLU + MSE + Adam.

```
class KappaNet(nn.Module):
    def __init__(self):
        super().__init__()
        self.net = nn.Sequential(
            nn.Linear(2, 32),
            nn.ReLU(),
            nn.Linear(32, 32),
            nn.ReLU(),
            nn.Linear(32, 1)
        )
    def forward(self, x):
        return self.net(x)

criterion = nn.MSELoss()
optimizer = optim.Adam(
    model.parameters(), lr=1e-3
)
```

## Практика 2: фононный спектр с NEP

В notebook используется готовый потенциал NEP для Si.

### Последовательность

1. загрузить структуру и NEP;
2. релаксировать структуру;
3. вычислить силовые константы;
4. построить  $k$ -путь;
5. получить фононный спектр и DOS.

POSCAR  $\rightarrow$  NEP  $\rightarrow \Phi^{(2)} \rightarrow \omega(\mathbf{q})$

```
from ase.io import read
from calorine.calculators import CPUNEP
from calorine.tools import (
    get_force_constants,
    relax_structure
)

structure = read("POSCAR-Si")
calculator = CPUNEP("Si_NEP.txt")
structure.calc = calculator

relax_structure(structure, fmax=1e-4)
phonon = get_force_constants(
    structure, calculator, [4, 4, 4]
)
```

# Итоги лекции

## Что мы научились различать

- surrogate model — аппроксимация дорогого отображения;
- PINN — обучение с физическими ограничениями;
- MLIP — аппроксимация атомной потенциальной энергии и сил.

## Общая математическая идея

Во всех случаях строится модель с параметрами  $\theta$  и определяется цель:

$$\theta^* = \arg \min_{\theta} \mathcal{L}(\theta) .$$

Но содержание  $\theta$ , данных и функции потерь зависит от физической задачи.

**Машинное обучение расширяет инструментарий вычислительной физики, но не отменяет физическую постановку задачи.**