

Использование физически информированных нейронных сетей для идентификации материальных параметров в задаче теории упругости

Научный руководитель – Романов Александр Вячеславович

Шелепов Павел Игоревич

Студент (специалист)

Московский государственный университет имени М.В.Ломоносова,
Механико-математический факультет, Кафедра механики композитов, Москва, Россия
E-mail: pavel.shelepov@math.msu.ru

Рассматривается задача идентификации параметров материала по доступным измерениям перемещений в линейной упругости.

Пусть $\Omega \subset \mathbb{R}^2$, $\partial\Omega = \Gamma_D \cup \Gamma_N$. Для неизвестных параметров $\theta = (E, \nu)$ требуется восстановить поле перемещений $\mathbf{u}(x)$ и определить θ по данным $D = \{(\mathbf{x}_j, \tilde{\mathbf{u}}(x_j))\}_{j=1}^{N_{\text{data}}}$.

Прямая задача задаётся уравнениями [3]

$$\nabla \cdot \underset{\sim}{P}(\mathbf{u}, \theta) + \mathbf{f} = 0$$

$$\mathbf{u}|_{\Gamma_D} = 0$$

$$\underset{\sim}{P}(\mathbf{u}, \theta) \cdot \mathbf{n}|_{\Gamma_N} = \mathbf{S}$$

Где [2] $\underset{\sim}{P} = \underset{\sim}{C}_\theta : \underset{\sim}{\varepsilon}(\mathbf{u})$, $\underset{\sim}{\varepsilon}(\mathbf{u}) = \frac{1}{2}(\nabla \mathbf{u} + \nabla \mathbf{u}^T)$.

При предположении, что шум измерений является Гауссовым, задача эквивалентна минимизации квадратичной невязки по данным при выполнении механических ограничений. Предлагается решение на основе коллокационных физически информированных нейронных сетей [6]: поле аппроксимируется нейросетью $\mathbf{u}_w(x) = NN(\mathbf{x}; \mathbf{w})$, а ограничения вводятся методом штрафов [1].

Итоговая задача оптимизации (функция потерь [4]) имеет вид:

$$\begin{aligned} \mathcal{L}(\mathbf{w}, \theta) = & \rho_{\text{data}} \frac{1}{N_{\text{data}}} \sum_j \|\mathbf{u}_w(\mathbf{x}_j) - \tilde{\mathbf{u}}_j\|^2 + \\ & \rho_\Omega \frac{1}{N_\Omega} \sum_{x_i \in X_\Omega} \|\nabla \cdot \underset{\sim}{P}(\mathbf{u}_w(\mathbf{x}_i), \theta) + \mathbf{f}(\mathbf{x}_i)\|^2 + \\ & + \rho_N \frac{1}{N_N} \sum_{x_i \in X_N} \|\underset{\sim}{P}(\mathbf{u}_w(\mathbf{x}_i), \theta) \cdot \mathbf{n} - \mathbf{S}(\mathbf{x}_i)\|^2 + \\ & + \rho_D \frac{1}{N_D} \sum_{x_i \in X_D} \|\mathbf{u}_w(\mathbf{x}_i)\|^2 \end{aligned}$$

Суммы являются аппроксимациями интегральных норм невязок методом Монте-Карло, что устраняет необходимость построения сетки и позволяет обучать модель на произвольной геометрии.

Обучение [5] выполняется методом Adam с физическими ограничениями на θ . Реализация ориентирована на пакет NVIDIA PhysicsNeMo, представляющий собой фреймворк для PINN-обучения [7].

Источники и литература

- 1) Евтушенко Ю. Г. Численные методы решения задач нелинейного программирования, Журнал вычислительной математики и математической физики. 1976. Т. 16. № 2.
- 2) Победря, Георгиевский. Лекции по теории упругости. 1999
- 3) Тимошенко С.П., Гудьер Дж. Теория упругости, М. Наука, 1975
- 4) С. Bishop. Pattern Recognition and Machine Learning., Springer, 2006
- 5) D.E. Rumelhart, G.E. Hinton, R.J. Williams. Learning representations by back-propagating errors, Nature, 1986
- 6) Raissi M., Perdikaris P., Karniadakis G.E. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear PDEs. J. Comput. Phys., 2019.
- 7) NVIDIA. PhysicsNeMo Sym: Linear Elasticity. docs.nvidia.com/physicsnemo