

Опыт применения сверточных нейронных сетей к обратным задачам сейсмической разведки

В. И. Голубев

Московский физико-технический институт, Долгопрудный, Российская Федерация
Федеральное государственное автономное учреждение “Федеральный научный центр
Научно-исследовательский институт системных исследований Национального исследовательского
центра “Курчатовский институт”, Москва, Российская Федерация
ORCID: 0000-0003-3113-7299, e-mail: golubev.vi@mipt.ru

М. И. Анисимов

Московский физико-технический институт, Долгопрудный, Российская Федерация
ORCID: 0009-0004-3434-8475, e-mail: anisimov.mi@phystech.edu

Аннотация: Работа посвящена исследованию возможности применения современных сверточных нейронных сетей для решения задач восстановления положения геологических включений и оценки скалярных параметров используемых моделей по данным сейсмической разведки. Для формирования обучающих и валидационных выборок используются синтетические сейсмограммы, рассчитанные явно-неявными сеточно-характеристическими схемами. В работе рассмотрены две архитектуры сетей для задач совместного машинного обучения, проведено сравнение результатов рассчитываемых оценок с моделями одиночного прогноза. Продемонстрировано значимое повышение качества прогноза.

Ключевые слова: сейсмическая разведка, трещиноватые среды, математическое моделирование, сверточные нейронные сети, совместное машинное обучение.

Благодарности: Работа выполнена в рамках государственного задания НИЦ “Курчатовский институт” — НИИСИ по теме № FNEF-2024-0002 “Математическое моделирование многомасштабных динамических процессов и системы виртуального окружения” (1023032900401-5-1.2.1).

Для цитирования: Голубев В.И., Анисимов М.И. Опыт применения сверточных нейронных сетей к обратным задачам сейсмической разведки // Вычислительные методы и программирование. 2024. Специальный выпуск. 46–61. doi 10.26089/NumMet.2024s04.



Experience of applying convolutional neural networks to inverse problems of seismic exploration

Vasily I. Golubev

Moscow Institute of Physics and Technology, Dolgoprudny, Russia
Scientific Research Institute for System Analysis of the National Research Centre “Kurchatov Institute”,
Moscow, Russia

ORCID: 0000-0003-3113-7299, e-mail: golubev.vi@mipt.ru

Mikhail I. Anisimov

Moscow Institute of Physics and Technology, Dolgoprudny, Russia

ORCID: 0009-0004-3434-8475, e-mail: anisimov.mi@phystech.edu

Abstract: The paper is devoted to the study of the possibility of using modern convolutional neural networks to solve problems of reconstructing the position of geological inclusions and estimating the scalar parameters of the models used based on seismic exploration data. Synthetic seismograms calculated by explicit-implicit grid-characteristic schemes are used to form training and validation samples. The paper considers two network architectures for joint machine learning problems and compares the results of the calculated estimates with single forecast models. A significant increase in forecast quality is demonstrated.

Keywords: seismic survey, fractured media, mathematical simulation, convolutional neural networks, multi-task machine learning.

Acknowledgements: The work was carried out within the framework of the state task of the NRC “Kurchatov Institute” — SRISA on the topic No. FNEF-2024-0002 “Mathematical modeling of multi-scale dynamic processes and virtual environment systems” (1023032900401-5-1.2.1).

For citation: V. I. Golubev, M. I. Anisimov, “Experience of applying convolutional neural networks to inverse problems of seismic exploration,” Numerical Methods and Programming. 2024. Special Issue. 46–61. doi 10.26089/NumMet.2024s04.

1. Введение. Сейсмические полевые исследования являются основным методом разведки и оценки запасов для месторождений углеводородов. Актуальной является задача сейсмической интерпретации — восстановление свойств геологического пласта по сейсмическим данным. В частности, непосредственный прикладной интерес представляет локализация и оценка свойств трещиноватых геологических включений как флюидо-содержащих объектов и зон повышенной проницаемости, играющих ключевую роль при выборе схемы разработки месторождения.

Исходно работа по сейсмической интерпретации выполнялась инженерами вручную и сопровождалась разметкой потенциальных границ геологических слоев и оценкой их порупругих свойств [1]. Автоматизация этого процесса потенциально может значительно сократить время получения результата с нескольких дней до нескольких часов. Однако существующие классические методы сейсмической инверсии требуют многократного численного решения прямой задачи, т.е. являются вычислительно затратными [2, 3].

Альтернативой являются набирающие популярность в этой области методы машинного обучения нейронных сетей. Самые ранние работы использовали простые полносвязанные сети для решения одномерных задач [4, 5]. С ростом вычислительных мощностей появилась возможность использовать нейронные сети для многомерных (2D и 3D) обратных задач сейсмоки [6, 7]. С ростом масштаба и качества полевых исследований стало возможным обучать нейросетевые модели на больших объемах реальных данных [8]. Успешной практикой в сейсмической интерпретации на сегодняшний день является применение сверточных нейронных сетей [9, 10]. К наиболее актуальным решениям, согласно последним научным публикациям, относятся архитектуры с модулем внимания [11, 12] и циклические генеративно-состязательные сети [13].

Однако остается не до конца решенной проблема переобучения нейронных сетей. В работе [14] нами было показано, что методы совместного машинного обучения [15, 16] могут быть использованы для повышения качества прогноза и борьбы с переобучением. Целью настоящей работы является исследование возможности применения разработанных в [14] архитектур совместных нейронных сетей для решения практических задач сейсмической разведки.

2. Методы исследования.

2.1. Расчет синтетических сейсмограмм.

В работе рассматривались две обратные задачи. В первой задаче в неоднородном геологическом массиве, описываемом в рамках стандартной модели Marmousi2 [17] (линейно упругая двумерная неоднородная модель), помещалось трещиноватое включение, описываемое континуальной слоистой моделью [18]. Для расчета синтетических сейсмограмм применялась сеточно-характеристическая явно-неявная схема, предложенная в работе [19]. Обратная задача формулировалась как задача поиска места расположения трещиноватого включения и оценки скалярных параметров модели.

Во второй задаче в слоистой неоднородной модели, включающей слой льда, слой воды и горизонтально-слоистый геологический массив, располагался нефтяной резервуар переменного размера и местоположения. Для описания динамического поведения льда использовались модели Максвелла и Кукуджанова, а в остальной расчетной области процесс описывался в рамках изотропной линейно упругой модели [20]. Для расчета синтетических сейсмограмм использовался сеточно-характеристический метод на структурных сетках. Обратная задача формулировалась как задача пространственной локализации нефтяного резервуара.

Для численного расчета использовался вычислительный кластер с 12 ядрами Intel(R) Xeon(R) CPU E5-2620 v2 с тактовой частотой 2.10 ГГц и оперативной памятью 256 ГБ. Время расчета одной прямой задачи составляло порядка 60 минут.

2.2. Задача о трещиноватом включении. В результате одного расчета прямой задачи получают сейсмограммы горизонтальной v_x и вертикальной v_y компонент скорости смещения, записанные на дневной поверхности набором из 351 сейсмоприемника с дискретизацией в 341 временной интервал (рис. 1). Необходимо по данной сейсмограмме локализовать трещиноватое включение и оценить скалярные параметры используемой модели.

Для обучения моделей, использующихся для обучения нейронных сетей, и оценки качества их прогноза требуется подготовить достаточно большую и репрезентативную выборку. Для этого мы варьируем

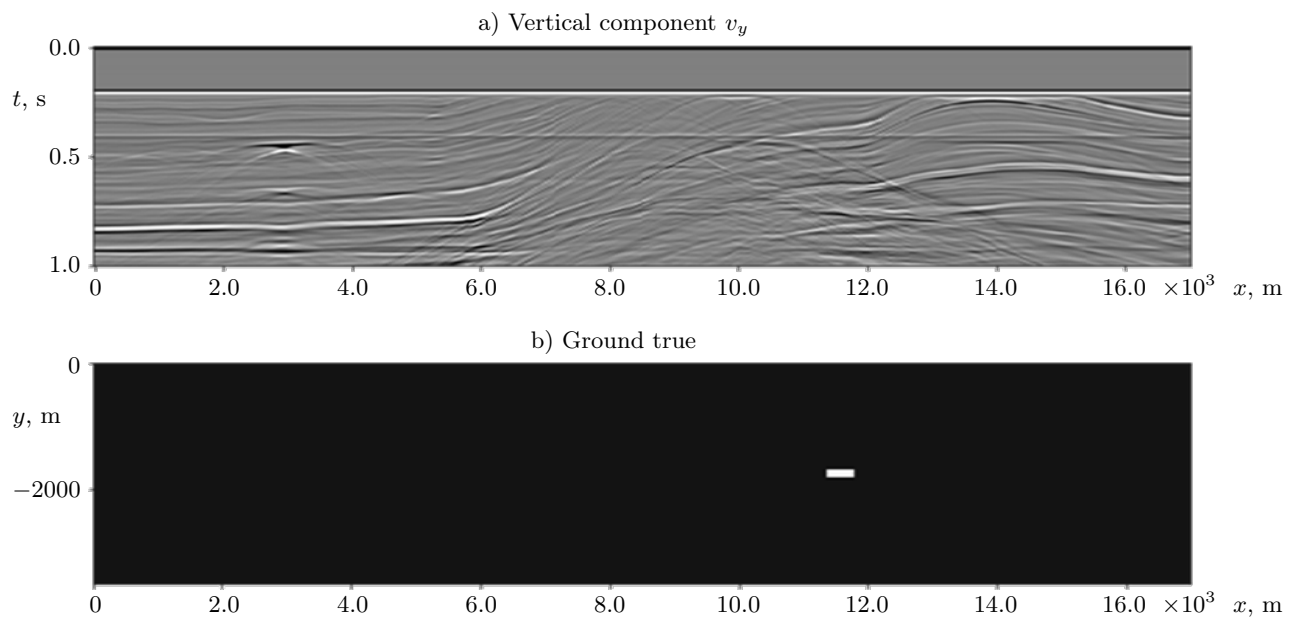


Рис. 1. К задаче о трещиноватом включении: а) синтетическая сейсмограмма v_y ; б) разметка для расчетной области (белый цвет — трещиноватое включение, черный цвет — вмещающая среда)

Fig. 1. To the problem of a fractured inclusion: а) generated seismogram for v_y component; б) marking for the computational domain (white color — fractured inclusion, black color — host medium)

вали положение трещиноватого включения и скалярные параметры модели в достаточно широком диапазоне. Для каждой полученной геологической модели рассчитывались сейсмограммы v_x и v_y компонент скорости. Таким образом, из попарно соответствующих геологических моделей и сейсмограмм составляется требуемая выборка. Нами были подготовлены две различные модификации выборки, каждая — размером в 6000 объектов (сейсмограмм):

- 1) выборка с 300 уникальными положениями трещиноватого включения, для каждого из которых варьировался угол наклона трещин (20 значений от -20° до 20°) с фиксированным коэффициентом трения 0.1;
- 2) выборка с 300 уникальными положениями трещиноватого включения, для каждого из которых варьировался коэффициент трения (20 значений от 0.01 до 0.1) с фиксированным углом наклона трещин в 10° .

Каждая из подготовленных выборок была разделена на обучающую и тестовую части с непересекающимися областями трещиноватого включения во избежание утечки тестовой выборки в обучающую. Разбиение на выборки было сделано равномерно по вертикальной координате y , чтобы впоследствии оценить влияние глубины расположения трещиноватой зоны на качество предсказания. Дополнительно, для обеспечения корректности работы слоев BatchNorm нейронных сетей, выгрузка обучающей выборки производилась выборками данных (batches) с неповторяющимися положениями трещиноватого включения.

2.3. Архитектуры используемых сверточных нейронных сетей. Для решения обратной задачи используются сверточные нейронные сети, обученные на обучающей части выборки. Сначала рассмотрим подробнее архитектуры сетей, используемых для отдельного прогноза положения и скалярных свойств трещиноватого включения, которые будут служить основными моделями для сравнения.

Для одиночного предсказания скалярных параметров модели используется нейронная сеть с 181508 обучаемыми параметрами (рис. 2 а), состоящая из сверточных слоев (синие блоки) и слоев выбора максимального элемента (белые блоки). На вход в модель подается сейсмограмма из v_x и v_y компонент в виде

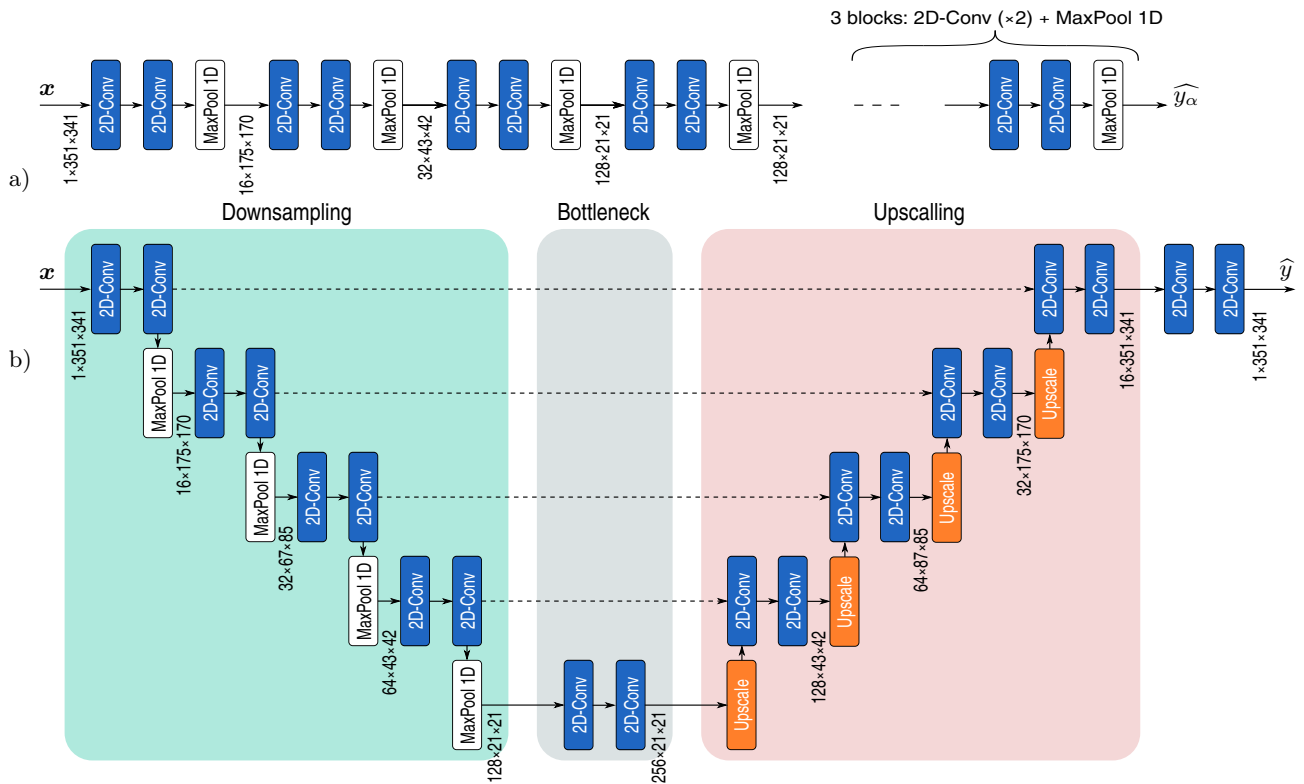


Рис. 2. Архитектуры моделей одиночного предсказания [14]: а) модель регрессии скаляра; б) модель для локализации трещиноватого включения

Fig. 2. Architectures of single-target models [14]: a) scalar regression model; б) model for localization of fractured inclusion

вектора входных параметров x , которая, путем последовательных сверток, преобразуется в скаляр y на выходе.

Для задачи обнаружения трещиноватой области была выбрана классическая 2D модель U-net [21], хорошо зарекомендовавшая себя во многих физических задачах. Рассматриваемая модель состоит из 196542 обучаемых параметров. На вход в U-net подается сейсмограмма из v_x и v_y компонент, которая проходит через сверточную часть и уменьшается в размере (downsampling), а после масштабируется (upscaling) с учетом отфильтрованных признаков на прошлых слоях, которые передаются напрямую (пунктирные линии на схеме). На выходе сети получается карта вероятностей наличия трещин в каждом пикселе области.

Для повышения качества прогноза нами были разработаны следующие архитектуры совместного машинного обучения: совмещенная модель (рис. 3) и перекрестная модель (рис. 4). Методы совместного машинного обучения обладают следующими преимуществами, важными для задачи сейсмической интерпретации: выработка лучшей селективной способности за счет обучения на несколько задач сразу, эффективная борьба с переобучением за счет предобуславливания на несколько задач, борьба с шумом в целевых переменных.

В совмещенной модели (рис. 3) признаки, отфильтрованные в подмодели U-net для обнаружения трещиноватого включения, передаются напрямую в подмодель для регрессии скалярной переменной. Совмещенная модель состоит из 2269045 обучаемых параметров и соответствует схеме явного разделения параметров в методах совместного машинного обучения [16]. Улучшение качества прогноза в такой модели достигается за счет явного учета пространственных признаков, отфильтрованных в подмодели для задачи обнаружения, при решении задачи регрессии.

Перекрестная модель (рис. 4) соединяет подмодели с помощью специальных обучаемых перекрестных блоков (зеленые блоки на рис. 4) [22]. Эти блоки получают на вход промежуточные признаки от

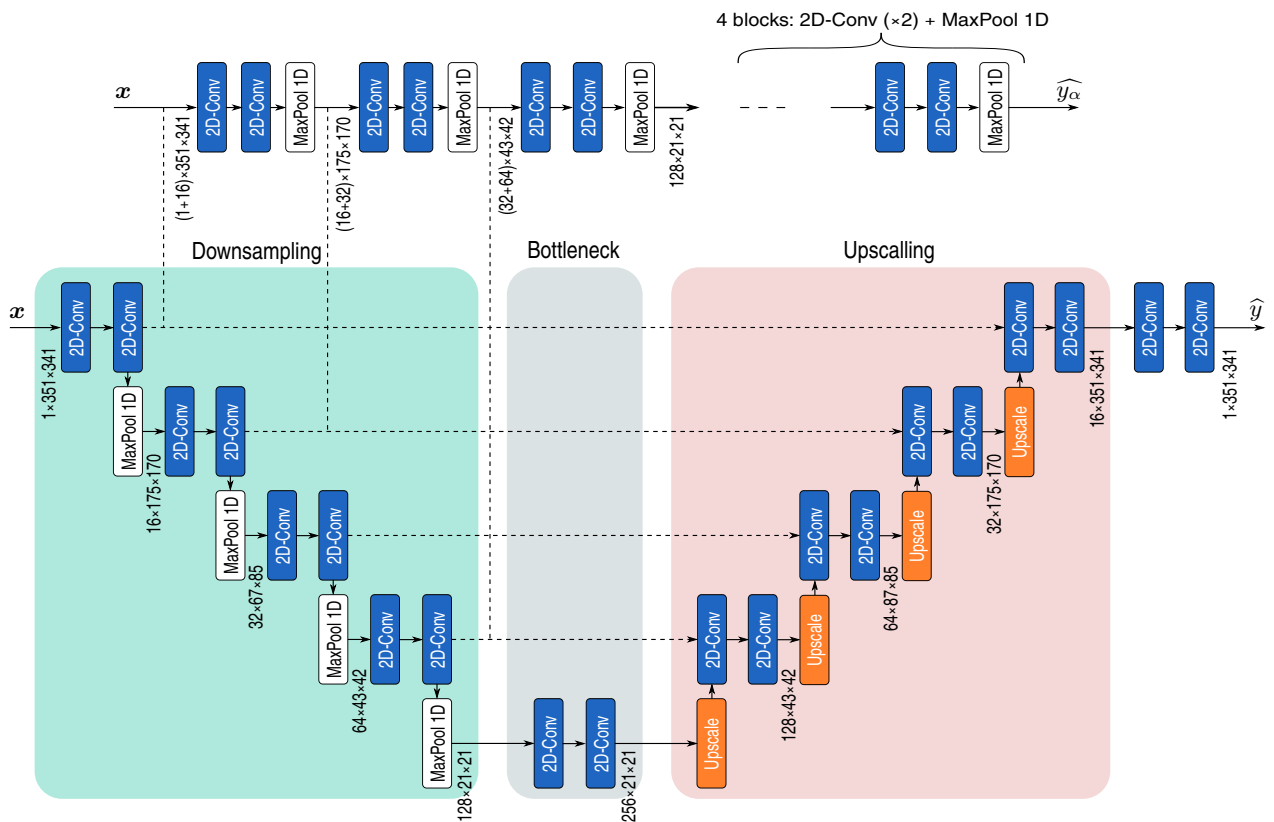


Рис. 3. Архитектура совмещенной нейронной сети

Fig. 3. Architecture of stacked model

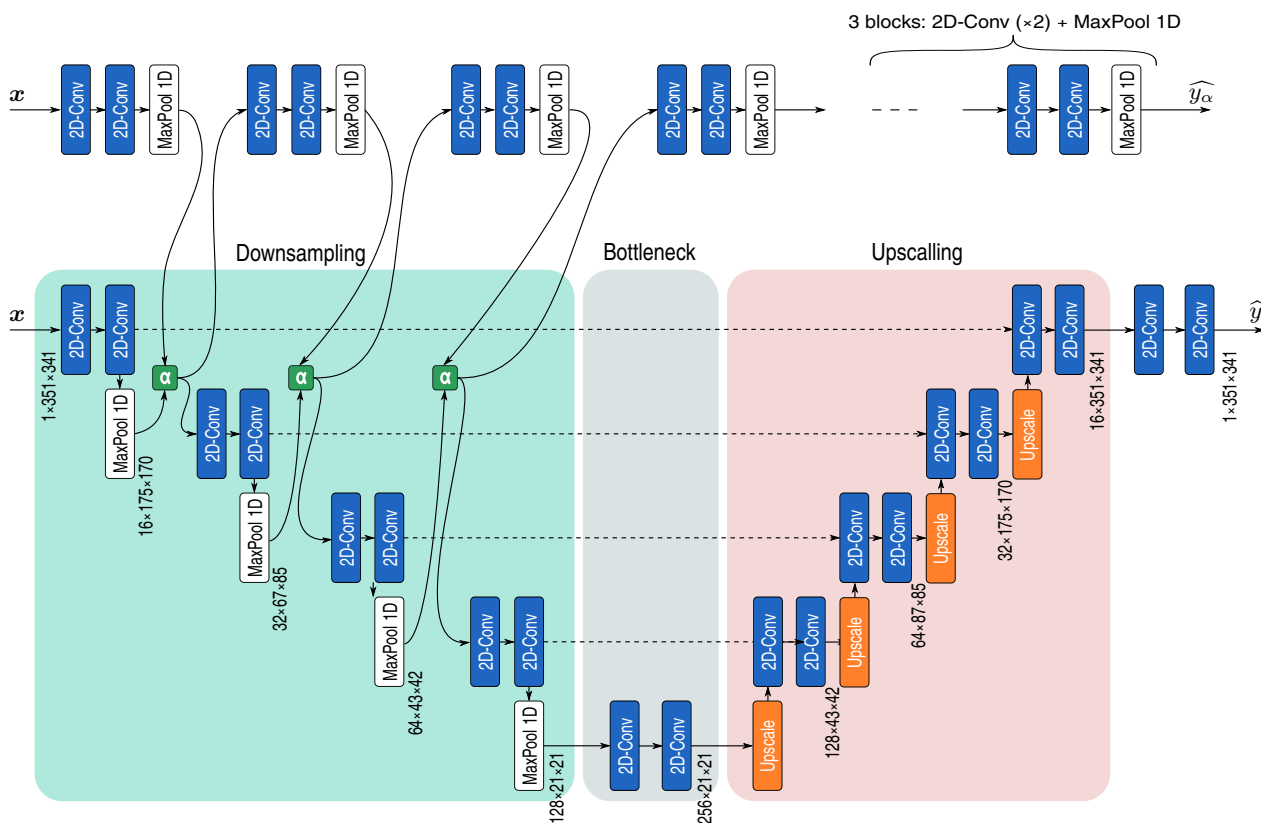


Рис. 4. Архитектура перекрестной нейронной сети

Fig. 4. Architecture of cross-stitch model

подмоделей и передают в последующие слои линейную комбинацию собственных и смежных признаков:

$$\begin{pmatrix} \tilde{\mathbf{x}}_1 \\ \tilde{\mathbf{x}}_2 \end{pmatrix} = \begin{pmatrix} \alpha_{11} & \alpha_{12} \\ \alpha_{21} & \alpha_{22} \end{pmatrix} \begin{pmatrix} \mathbf{x}_1 \\ \mathbf{x}_2 \end{pmatrix}.$$

Здесь \mathbf{x}_1 , \mathbf{x}_2 — входные признаки, поступающие в перекрестный блок, $\tilde{\mathbf{x}}_1$, $\tilde{\mathbf{x}}_2$ — выходные признаки, которые передаются на вход в последующие слои подмоделей, α_{ij} — коэффициенты, полученные при обучении перекрестного блока.

Архитектура перекрестной модели состоит из 2146951 обучаемых параметров. Такой подход является максимально гибким и позволяет модели выучить явным образом степень связанности задач на уровне коэффициентов в перекрестных блоках. Отметим также, что для эффективного обучения перекрестных сетей требуется масштабирование шага обучения для перекрестных модулей, подробно описанное в [22].

2.4. Функция потерь для совместного обучения. При обучении нейросетей совместного предсказания минимизируется комбинированная функция потерь всех целевых переменных. Во избежание выработки предпочтения при обучении в сторону задачи с ошибкой меньшего масштаба важно использовать сбалансированную комбинированную функцию потерь. Дополнительная сложность возникает ввиду разнородности рассматриваемых задач: сегментации и регрессии скаляра. Мы использовали для обучения комбинированную функцию потерь из среднеквадратичной ошибки (MSE) предсказания скаляра, нормированной на дисперсию скалярной величины, и взвешенной бинарной кросс-энтропии (BCE) для задачи обнаружения трещиноватого включения:

$$\text{Loss}(y, \hat{y}, y_s, \hat{y}_s) = \frac{1}{N} \sum_{i=1}^N -\frac{1}{M} (w_p y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)) + \frac{(\hat{y}_{s,i} - y_{s,i})^2}{D(y_s)}. \quad (1)$$

Здесь N — число объектов в выборке, M — число пикселей в сегментационной карте, y — истинная разметка области, \hat{y} — предсказанная карта вероятностей, y_s — истинное значение скалярной переменной

(угла наклона трещин или коэффициента трения), \hat{y}_s — предсказанное значение скаляра, $w_p = 42.5$ — вес положительных меток в ВСЕ, $D(y_s)$ — дисперсия целевой скалярной переменной.

3. Результаты.

3.1. Метрики для оценки качества прогноза. В целях демонстрации влияния совместного машинного обучения на качество прогноза мы обучили совместные модели из раздела 2.3 и их аналоги одиночного прогноза на наборах, описанных в разделе 2.2, с одинаковыми параметрами обучения. Каждая модель обучалась на протяжении 300 эпох оптимизатором Adam, представленном в пакете PyTorch, с шагом обучения $5 \cdot 10^{-5}$. Далее обученные модели валидировались на соответствующей набору данных тестовой выборке и сравнивались между собой по выбранным метрикам качества предсказания.

Качество регрессии скалярной величины в работе оценивается по величине среднеквадратичной ошибки (MSE) и коэффициенту детерминации (R^2). Для оценки качества предсказания карты сегментации используются классические метрики машинного обучения: Precision, Recall и Dice Score.

Обучение производилось на персональном компьютере с двумя видеокартами GeForce(R) RTX 3060 Lite Hash Rate. Характерное время обучения U-net модели и моделей совместного обучения составило порядка 150 минут, и потребовалось менее 1 ГБ оперативной памяти. Обучение сверточной сети одиночного предсказания скаляра заняло менее 30 минут ввиду ее легковесности и потребовало менее 1 ГБ оперативной памяти.

3.2. Предсказание положения трещиноватого включения и угла наклона трещин. В данной задаче обе модели совместного машинного обучения (совмещенная и перекрестная) демонстрируют улучшение качества прогноза по сравнению со сверточной сетью одиночного предсказания (табл. 1). Так, для совмещенной модели наблюдается улучшение на 56% среднеквадратичной ошибки (MSE) по сравнению с моделью одиночного прогноза. Отметим, что модели совместного машинного обучения демонстрируют значительное уменьшение корреляции ошибки с глубиной залегания трещиноватой зоны (табл. 1).

Полученный результат наиболее наглядно виден на корреляционных диаграммах истинных и предсказанных значений угла (рис. 5). Для одиночной модели наблюдается большая дисперсионная область предсказания и систематическое ухудшение качества прогноза для больших значений угла. В то же время совместные модели демонстрируют меньшую дисперсию предсказания и хорошее соответствие эталонной прямой $y = x$. При этом наилучший результат показывает совмещенная модель.

Обе модели демонстрируют повышение качества предсказания положения трещиноватого включения при обучении на эту задачу совместно с задачей регрессии угла наклона трещин (табл. 2). Так, метрика

Таблица 1. Сравнение совместных моделей и сверточной сети одиночного прогноза на задаче о регрессии угла
 Table 1. Comparison of multi-task models and single-target convolution network on angle regression task

Модель Model	Сравнение метрик Comparison of metrics		Корреляция MSE Correlation of MSE	
	MSE	R^2	x	y
CNN (одиночное предсказание) Single-target CNN	11.26	0.92	0.1023	-0.1343
Совмещенная модель Stacked model	4.90	0.97	0.0216	0.0136
Перекрестная модель Cross-stitch model	8.94	0.94	0.0780	-0.2378

Таблица 2. Сравнение метрик обнаружения трещиноватого включения
 Table 2. Comparison of metrics for fractured inclusion detection task

Model	Precision	Recall	Dice Score
U-net (одиночное предсказание) U-net (single-target)	0.70	0.67	0.53
Совмещенная модель Stacked model	0.76	0.70	0.77
Перекрестная модель Cross-stitch model	0.74	0.75	0.74

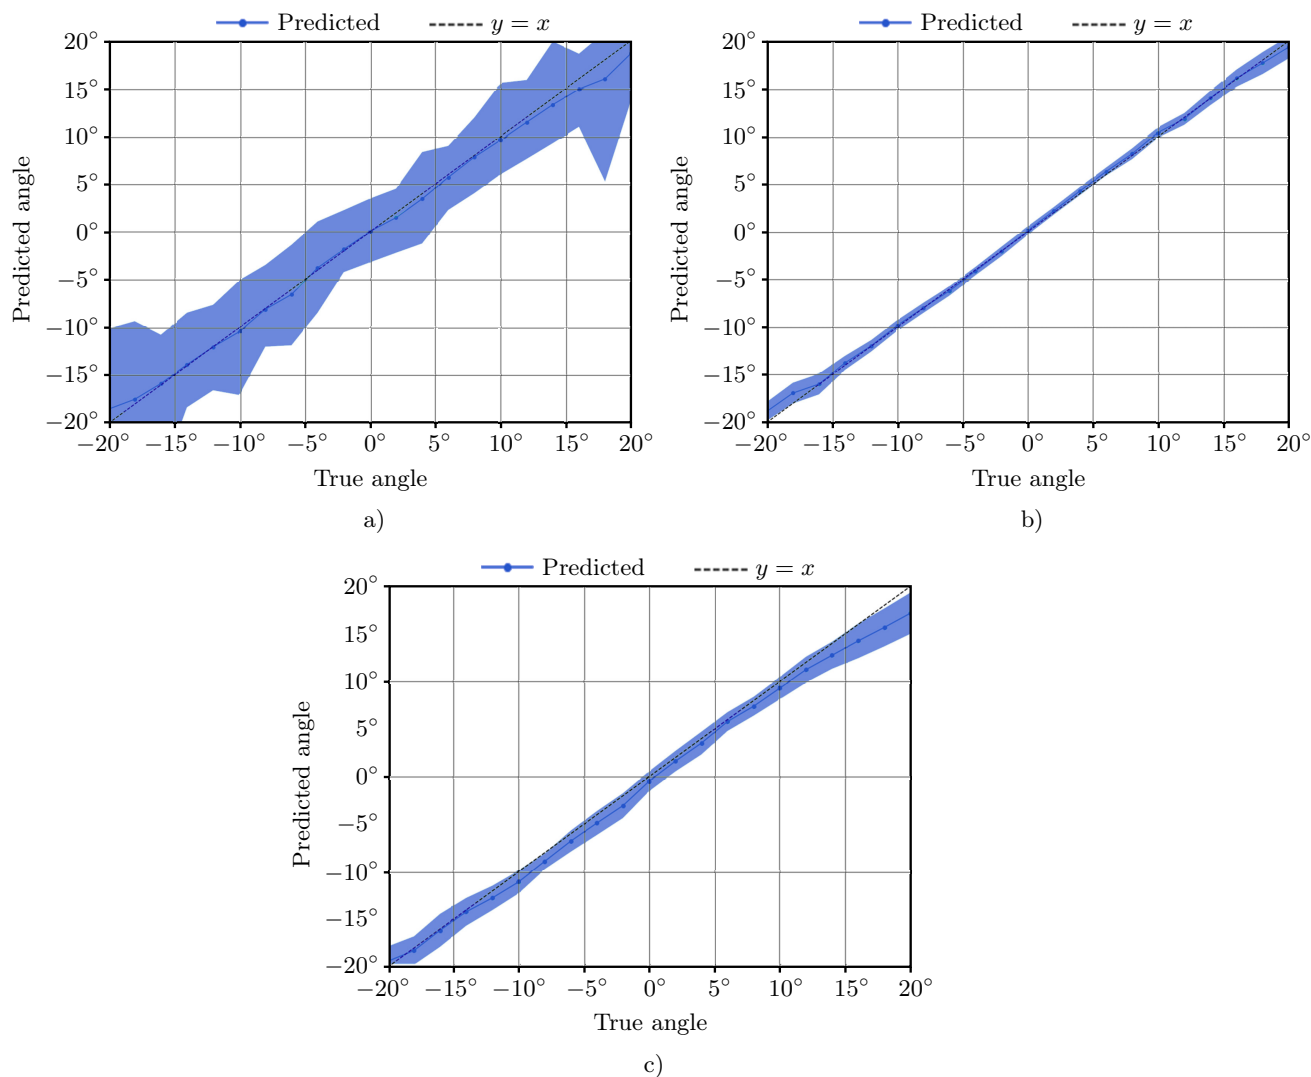


Рис. 5. Корреляционная диаграмма истинных и предсказанных значений угла наклона трещин:
 а) для сверточной сети одиночного предсказания; б) для совмещенной модели; в) для перекрестной модели

Fig. 5. Cross plot of predicted and true values for fracture orientation angle:
 а) for single-target CNN; б) for stacked model; в) for cross-stitch model

Dice Score выше на 40% для перекрестной модели и на 45% для совмещенной по сравнению с обычной U-net моделью. Однако метрики Precision и Recall изменились слабо. Это говорит о росте уверенности модели в прогнозе, но неизменности предсказанных дискретных меток. Для одиночной модели U-net неуверенность проявляется в размытых границах на краях трещиноватой зоны в предсказанных картах вероятностей (рис. 6).

3.3. Предсказание положения трещиноватого включения и коэффициента трения трещин. Был поставлен эксперимент на датасете с варьируемым коэффициентом трения (табл. 3). Однако не удалось зафиксировать улучшение качества прогноза при применении совместного машинного обучения.

На корреляционных диаграммах истинного и предсказанного значения коэффициента трения (рис. 7) также наблюдается ухудшение качества предсказания для больших значений коэффициентов трения для совмещенной и перекрестной моделей по сравнению с моделью одиночного предсказания.

В то же время модели совместного обучения демонстрируют значительное повышение качества предсказания разметки трещиноватой области (табл. 4). По метрике Dice Score совмещенная и перекрестная модели демонстрируют повышение на 25% и 32% соответственно. По метрике Recall наблюдается незначительное ухудшение для совместных моделей.

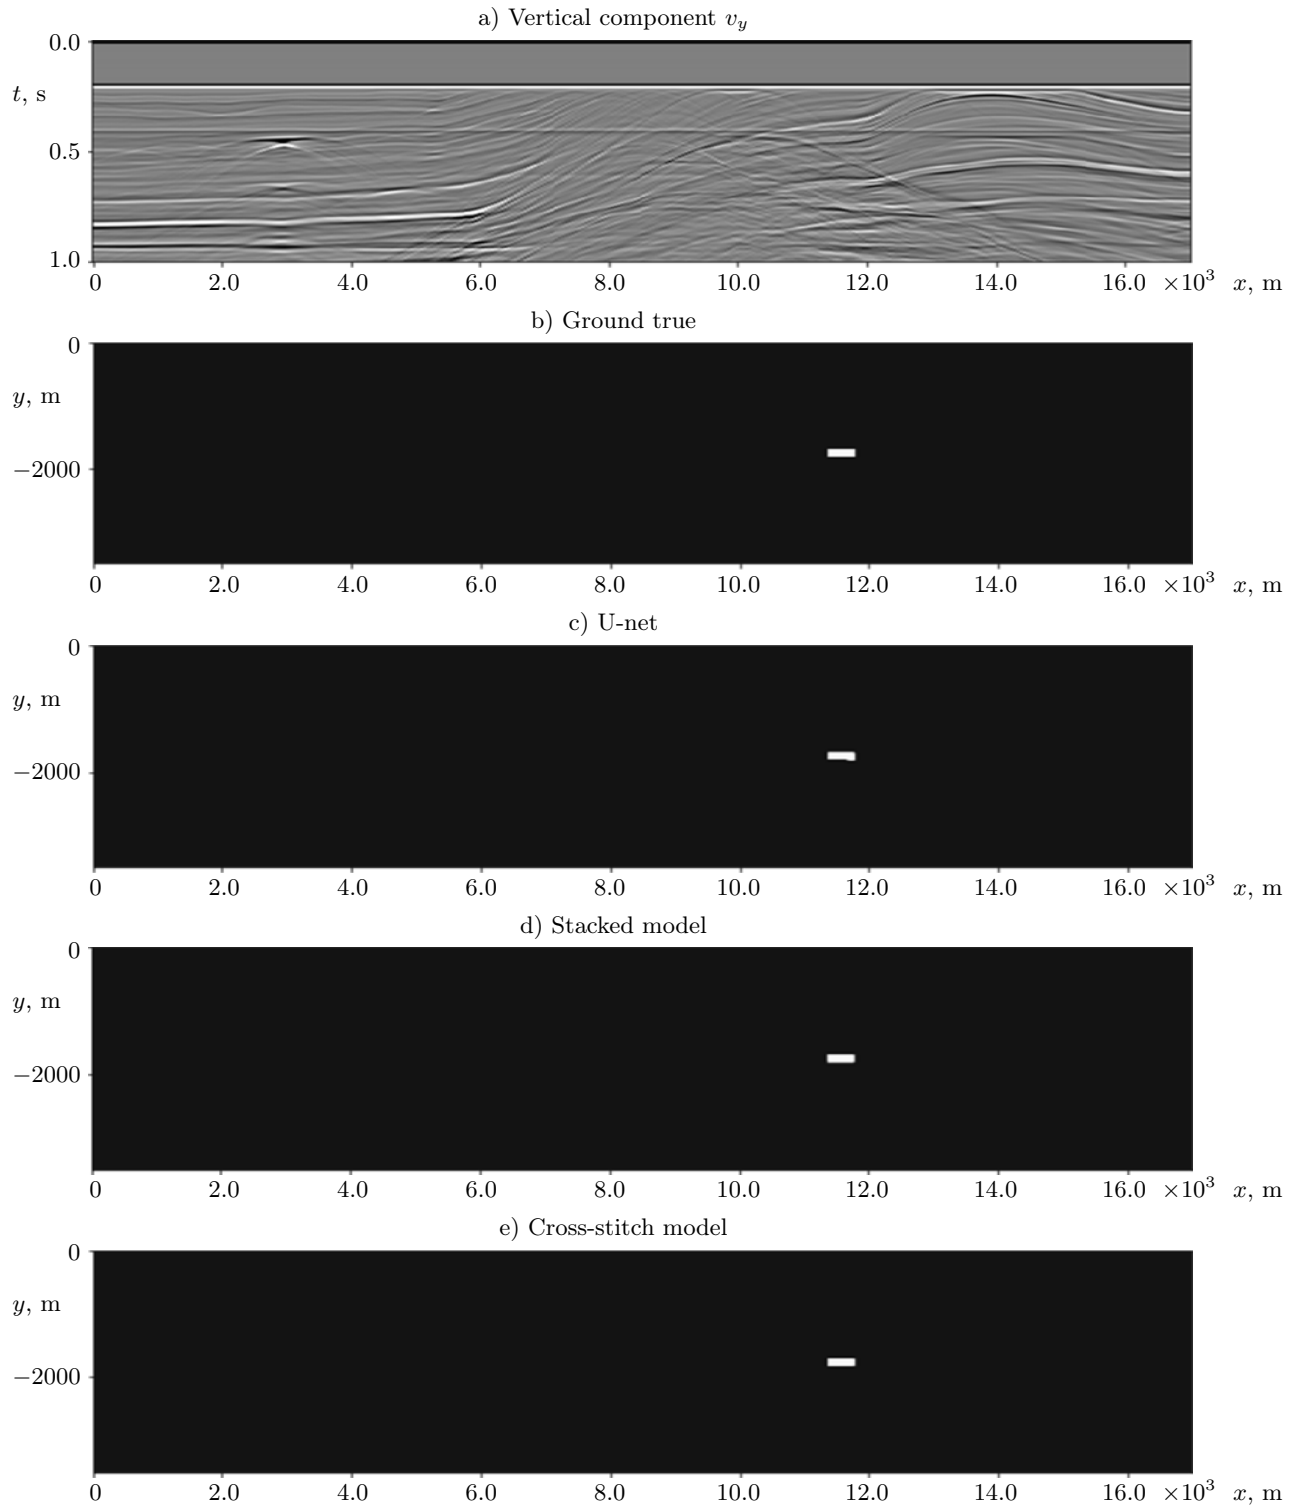


Рис. 6. К предсказанию положения трещиноватого включения: а) сейсмограмма для v_y ; б) истинная разметка трещиноватой области; в) предсказанная U-net карта вероятностей; д) предсказанная совмещенной моделью карта вероятностей; е) предсказанная перекрестной моделью карта вероятностей

Fig. 6. To predict the position of a fractured inclusion: a) gathering for v_y ; b) true marking of the fractured region; c) predicted U-net probability map; d) predicted probability map by the coupled model; e) predicted probability map by the cross-model



Таблица 3. Сравнение совместных моделей и сверточной сети одиночного прогноза на задаче регрессии коэффициента трения

Table 3. Comparison of multi-task models and single-target convolution models on Coulomb's friction coefficient regression task

Модель Model	Сравнение метрик Comparison of metrics		Корреляция MSE Correlation of MSE	
	MSE	R^2	x	y
CNN (одиночное предсказание) Single-target CNN	0.0068	0.16	0.247	-0.185
Совмещенная модель Stacked model	0.0083	-0.07	0.0585	0.0965
Перекрестная модель Cross-stitch model	0.0086	-0.13	0.0284	0.0304

Таблица 4. Сравнение метрик обнаружения трещиноватого включения

Table 4. Comparison of metrics for fractured inclusion detection task

Model	Precision	Recall	Dice Score
U-net (одиночное предсказание) U-net (single-target)	0.78	0.76	0.59
Совмещенная модель Stacked model	0.77	0.65	0.74
Перекрестная модель Cross-stitch model	0.76	0.79	0.78

Исследование зависимости метрики Dice Score от глубины залегания включения выявило значительное улучшение качества предсказания при применении методов совместного обучения по сравнению с предсказанием одиночной модели U-net. Дополнительно отметим, что для совместных моделей не наблюдается четко выраженный тренд понижения качества прогноза с увеличением глубины залегания трещиноватой зоны, что потенциально говорит об их лучшей обобщающей способности по сравнению с одиночной моделью.

Мы предлагаем следующее объяснение полученного результата: задачи регрессии коэффициента трения и предсказания разметки области трещиноватого включения слабо связаны. Положение трещиноватой зоны влияет на положение сейсмического отклика на сейсмограмме. В то же время значение коэффициента трения влияет только на внутреннюю структуру отклика (рис. 8). Поэтому оптимум функции потерь (1) находится в точке, где предоставленные дополнительные слои и информация для обучения используются для значительного улучшения качества предсказания разметки области при слабом ухудшении качества регрессии скаляра. Возможно, данной проблемы можно избежать дополнительным взвешиванием слагаемых в функции потерь. Однако, данный вопрос требует дальнейшего исследования.

3.4. Задача о нефтяном резервуаре. Была изучена возможность применения архитектуры U-net к задачам с более сложной реологией сред (рис. 9). На данном рисунке слои 1–2 соответствуют ледовой шапке, слой 3 — прослойке воды, слои 4–7 и 9 соответствуют слоям геологического массива, прямоугольник 8 — нефтяному резервуару, погруженному в слой 7. В модели варьируются размеры и положение включения 8 внутри слоя 7. На ледовой шапке (слой 1) расположены два источника, генерирующие сейсмические волны. Ставится задача локализации включения 8 по сейсмическим измерениям.

Исследовался случай небольшой выборки, состоящей из 120 сейсмограмм с варьируемыми положением и размерами резервуара (150 × 26 м, 200 × 34 м, 300 × 50 м). При верификации модели (рис. 9) на тестовой выборке наблюдается соответствие истинных и предсказанных разметок (рис. 10), а также хорошие значения метрик прогноза: Precision = 0.95, Recall = 0.89, Dice Score = 0.66.

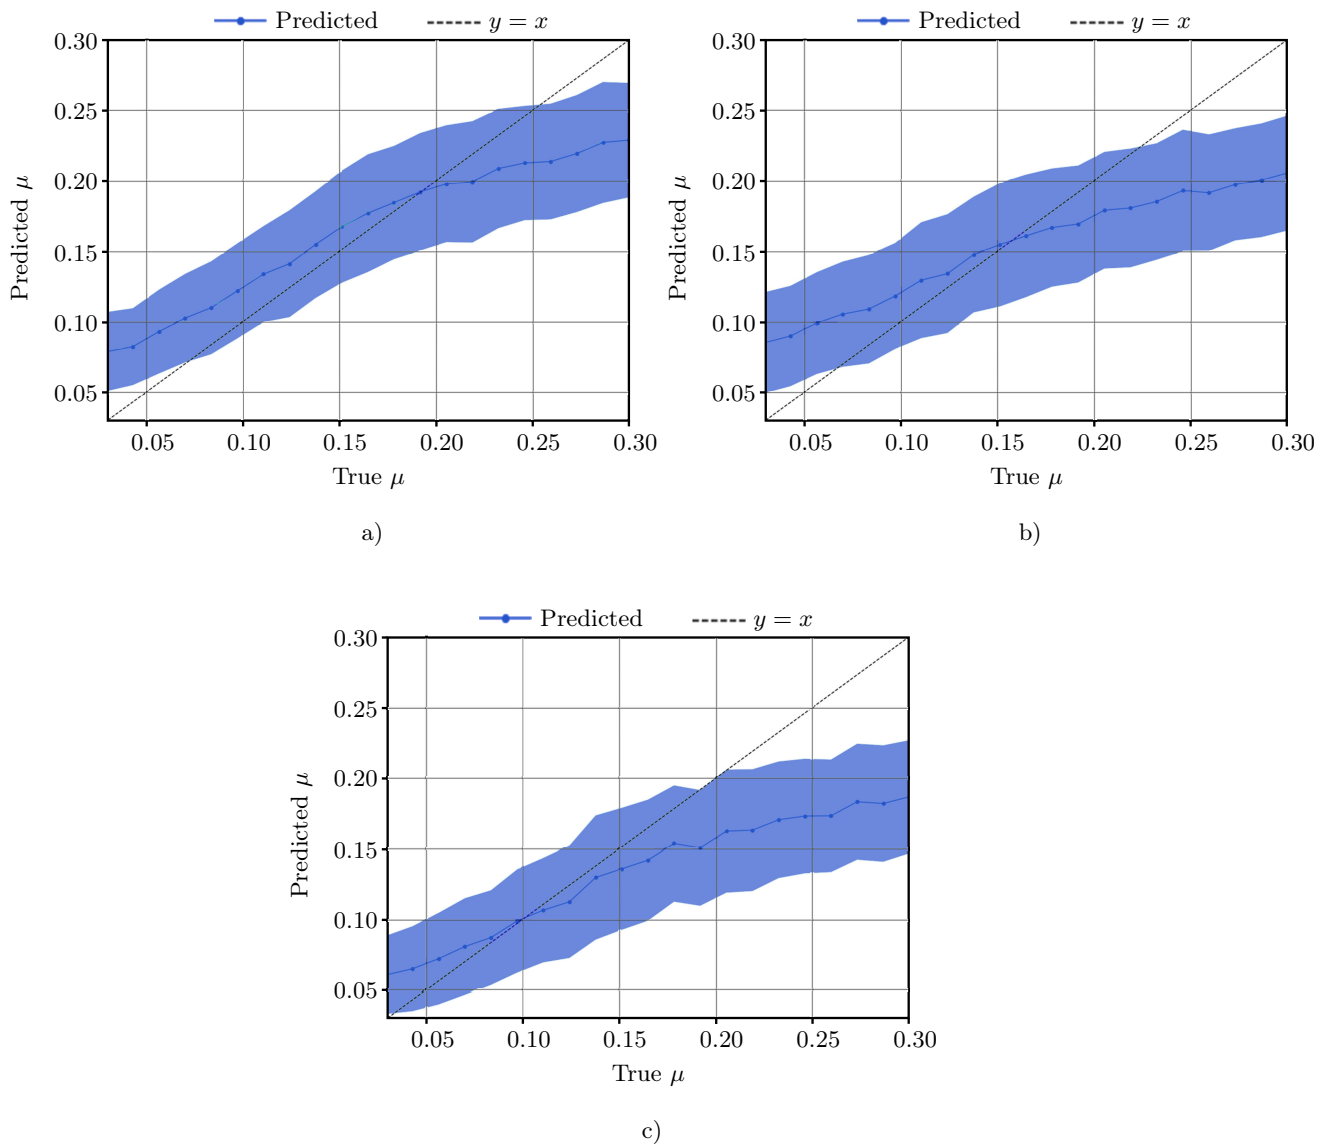


Рис. 7. Корреляционная диаграмма истинных и предсказанных значений коэффициента трения: а) для сверточной сети одиночного предсказания; б) для совмещенной модели; в) для перекрестной модели

Fig. 7. Cross plot of predicted and true values for Coulomb's friction coefficient: a) for single-target CNN; b) for stacked model; c) for cross-stitch model




Рис. 8. Сейсмический отклик для фиксированного положения трещиноватого включения ($x = 9000$ м, $y = 1100$ м) и разных коэффициентов трения. На диагональных графиках представлен сейсмический сигнал за вычетом фонового сигнала. На недиагональных графиках представлена попарная разница сигналов, полученных при разных коэффициентах трения, для наглядности масштаб был сделан в 10 раз больше изначального

Fig. 8. Visualization of a seismic response of fracture inclusion with fixed position in space ($x = 9000$ m, $y = 1100$ m) and various Coulomb's friction coefficients. On non-diagonal plots a pairwise difference of responses is presented scaled 10 times

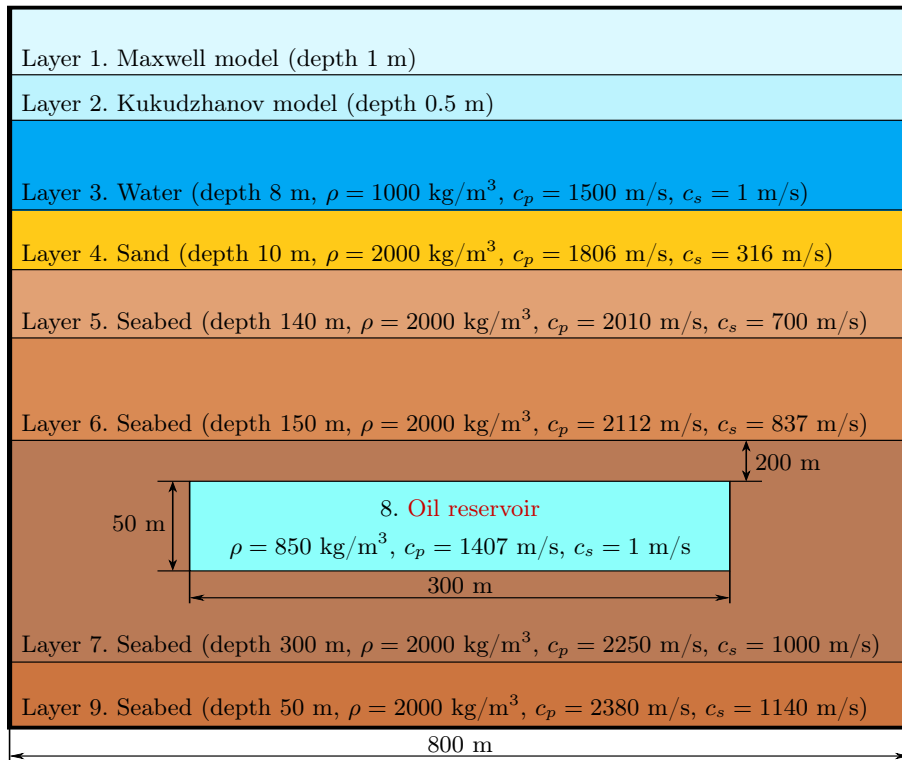


Рис. 9. Изображение рассматриваемой модели с нефтяным резервуаром [20]

Fig. 9. Model for oil reservoir detection task [20]




Рис. 10. Карта распределения вероятностей: а) истинная разметка; б) предсказание U-net

Fig. 10. Probability distribution map: a) true segmentation; b) prediction of U-net model



4. Заключение. В работе представлены результаты практического применения сверточных нейронных сетей для решения обратных задач сейсмической разведки. Проведенные расчеты позволяют сделать следующие выводы:

1. Применение совместных моделей к связанным задачам способствует повышению качества прогноза. Для задачи регрессии угла наклона трещин наблюдается улучшение на 56% по метрике MSE, для задачи обнаружения трещиноватого включения — на 45%. Положительный эффект прослеживается на корреляционных диаграммах истинного и предсказанного значения угла наклона, где совместные модели демонстрируют меньший разброс предсказаний и хорошее совпадение с прямой идеального прогноза.
2. Подтвержден нейтральный эффект обучения на несвязанные задачи предсказания коэффициента трения и положения трещиноватого включения для совместных моделей. Наблюдается значительное улучшение предсказания положения трещиноватой зоны при небольшом ухудшении регрессии скалярной величины. Данный эффект, вероятно, объясняется перекосом при обучении совместных моделей в сторону одной из задач.
3. Сверточные нейронные сети могут быть успешно применены в задачах со сложной реологией рассматриваемых сред.

Список литературы

1. *Badley M.E.* Practical seismic interpretation. Boston: IHRDC Publishers, 1985.
2. *Russel B., Hampson D.* Comparison of poststack seismic inversion methods // SEG Tech. Program Expand. Abstr. 1991. 876–878. doi [10.1190/1.1888870](https://doi.org/10.1190/1.1888870).
3. *Kosloff D., Sherwood J., Koren Z., et al.* Velocity and interface depth determination by tomography of depth migrated gathers // Geophysics. 1996. **61**, N 8. 1511–1523. doi [10.1190/1.1444076](https://doi.org/10.1190/1.1444076).
4. *Roeth G., Tarantola A.* Use of neural networks for inversion of seismic data // SEG Tech. Program Expand. Abstr. 1991. 302–305. doi [10.1190/1.1888938](https://doi.org/10.1190/1.1888938).
5. *Röth G., Tarantola A.* Neural networks and inversion of seismic data // Journal of Geophysical Research: Solid Earth. 1994. **99**, N B4. 6753–6768. doi [10.1029/93JB01563](https://doi.org/10.1029/93JB01563).
6. *Leite E.P., Vidal A.C., Bueno J.F., Duarte R.D.C.* 3D acoustic impedance and porosity mapping from seismic inversion and neural networks // SEG Tech. Program Expand. Abstr. 2010. 2226–2230. doi [10.1190/1.3513291](https://doi.org/10.1190/1.3513291).
7. *Cao D., An P., Liu S.* Elastic-parameters inversion from EI based on the deep-learning method // SEG Tech. Program Expand. Abstr. 2018. 640–644. doi [10.1190/segam2018-2998479.1](https://doi.org/10.1190/segam2018-2998479.1).
8. *Eladj S., Doghmane M.Z., Aliouane L., Ouadfeul S.-A.* Porosity model construction based on ANN and seismic inversion: a case study of Saharan field (Algeria) // Advances in Geophysics, Tectonics and Petroleum Geosciences. Cham: Springer, 2022. 241–243. doi [10.1007/978-3-030-73026-0_55](https://doi.org/10.1007/978-3-030-73026-0_55).
9. *Lewis W., Vigh D.* Deep learning prior models from seismic images for full-waveform inversion // SEG Tech. Program Expand. Abstr. 2017. 1512–1517. doi [10.1190/segam2017-17627643.1](https://doi.org/10.1190/segam2017-17627643.1).
10. *Wu B., Meng D., Wang L., et al.* Seismic impedance inversion using fully convolutional residual network and transfer learning // IEEE Geosci. Remote Sens. Lett. 2020. **17**, N 12. 2140–2144. doi [10.1109/LGRS.2019.2963106](https://doi.org/10.1109/LGRS.2019.2963106).
11. *Dodda V.C., Kuruguntla L., Razak S., et al.* Seismic lithology interpretation using attention based convolutional neural networks // 2023 3rd Int. Conf. on Intelligent Communication and Computational Techniques. 2023. 1–5. doi [10.1109/ICCT56969.2023.10075964](https://doi.org/10.1109/ICCT56969.2023.10075964).
12. *Sun Q., Wang X., Ni H., et al.* Fault identification of U-net based on enhanced feature fusion and attention mechanism // Electronics. 2023. **12**, N 12. Article Number 2562. doi [10.3390/electronics12122562](https://doi.org/10.3390/electronics12122562).
13. *Wang Y.-Q., Wang Q., Lu W.-K., et al.* Seismic impedance inversion based on cycle-consistent generative adversarial network // Pet. Sci. 2022. **19**, N 1. 147–161. doi [10.1016/j.petsci.2021.09.038](https://doi.org/10.1016/j.petsci.2021.09.038).
14. *Golubev V., Anisimov M.* Application of convolutional networks for localization and prediction of scalar parameters of fractured geological inclusion // Int. J. of Applied Mechanics. 2024. **16**, N 5. Article Number 2450064. doi [10.1142/S1758825124500649](https://doi.org/10.1142/S1758825124500649).
15. *Zhang Y., Yang Q.* An overview of multi-task learning // National Science Review. 2018. **5**, N 1, 30–43. doi [10.1093/nsr/nwx105](https://doi.org/10.1093/nsr/nwx105).
16. *Crawshaw M.* Multi-task learning with deep neural networks: a survey // arXiv:2009.09796v1 [cs.LG]. 2020. doi [10.48550/arXiv.2009.09796](https://doi.org/10.48550/arXiv.2009.09796).

17. *Martin G.S., Wiley R., Marfurt K.J.* Marmousi2: an elastic upgrade for Marmousi // *The Leading Edge*. 2006. **25**, N 2. 156–166. doi [10.1190/1.2172306](https://doi.org/10.1190/1.2172306).
18. *Nikitin I.S., Burago N.G., Golubev V.I., Nikitin A.D.* Continual models of layered and block media with slippage and delamination // *Procedia Structural Integrity*. 2019. **23**, 125–130. doi [10.1016/j.prostr.2020.01.074](https://doi.org/10.1016/j.prostr.2020.01.074).
19. *Nikitin I.S., Golubev V.I.* Explicit-implicit schemes for calculating the dynamics of layered media with nonlinear conditions at contact boundaries // *Журн. СФУ. Сер. Матем. и физ.* 2021. **14**, № 6. 768–778. doi [10.17516/1997-1397-2021-14-6-768-778](https://doi.org/10.17516/1997-1397-2021-14-6-768-778).
20. *Петров И.Б., Голубев В.И., Гусева Е.К.* Гибридные сеточно-характеристические схемы для задач арктической сейсморазведки // *Докл. РАН*. 2021. **501**, № 1. 67–73. doi [10.31857/S2686954321060138](https://doi.org/10.31857/S2686954321060138).
21. *Ronneberger O., Fischer P., Brox T.* U-net: convolutional networks for biomedical image segmentation // *Lecture Notes in Computer Science*. Vol. 9351. Cham: Springer, 2015. 234–241. doi [10.1007/978-3-319-24574-4_28](https://doi.org/10.1007/978-3-319-24574-4_28).
22. *Misra I., Shrivastava A., Gupta A., Hebert M.* Cross-stitch networks for multi-task learning // *Proc. IEEE Conf. on Computer Vision and Pattern Recognition*. Las Vegas, USA. 2016. 3994–4003. doi [10.1109/CVPR.2016.433](https://doi.org/10.1109/CVPR.2016.433).

Поступила в редакцию
8 октября 2024 г.

Принята к публикации
28 ноября 2024 г.

Информация об авторах

Василий Иванович Голубев — д.ф.-м.н., профессор; 1) Московский физико-технический институт, Институтский переулок, д. 9, 141700, Долгопрудный, Российская Федерация; 2) Федеральное государственное автономное учреждение “Федеральный научный центр Научно-исследовательский институт системных исследований Национального исследовательского центра “Курчатовский институт”, Нахимовский проспект, д. 36, стр. 1, 117218, Москва, Российская Федерация.

Михаил Игоревич Анисимов — аспирант, мл. науч. сотр.; Московский физико-технический институт, Институтский переулок, д. 9, 141700, Долгопрудный, Российская Федерация.

References

1. M. E. Badley, *Practical Seismic Interpretation* (IHRDC Publishers, Boston, 1985).
2. B. Russel and D. Hampson, “Comparison of Poststack Seismic Inversion Methods,” *SEG Tech. Program Expand. Abstr.* 1991, 876–878 (1991). doi [10.1190/1.1888870](https://doi.org/10.1190/1.1888870).
3. D. Kosloff, J. Sherwood, Z. Koren, et al., “Velocity and Interface Depth Determination by Tomography of Depth Migrated Gathers,” *Geophysics* **61** (8), 1511–1523 (1996). doi [10.1190/1.1444076](https://doi.org/10.1190/1.1444076).
4. G. Roethe and A. Tarantola, “Use of Neural Networks for Inversion of Seismic Data,” *SEG Tech. Program Expand. Abstr.* 1991, 302–305 (1991). doi [10.1190/1.1888938](https://doi.org/10.1190/1.1888938).
5. G. Röth and A. Tarantola, “Neural Networks and Inversion of Seismic Data,” *J. Geophys. Res. Solid Earth* **99** (B4), 6753–6768 (1994). doi [10.1029/93JB01563](https://doi.org/10.1029/93JB01563).
6. E. P. Leite, A. C. Vidal, J. F. Bueno, and R. D. C. Duarte, “3D Acoustic Impedance and Porosity Mapping from Seismic Inversion and Neural Networks,” *SEG Tech. Program Expand. Abstr.* 2010, 2226–2230 (2010). doi [10.1190/1.3513291](https://doi.org/10.1190/1.3513291).
7. D. Cao, P. An, and S. Liu, “Elastic-Parameters Inversion from EI Based on the Deep-Learning Method,” *SEG Tech. Program Expand. Abstr.* 2018, 640–644 (2018). doi [10.1190/segam2018-2998479.1](https://doi.org/10.1190/segam2018-2998479.1).
8. S. Eladj, M. Z. Doghmane, L. Aliouane, and S.-A. Ouadfeul, “Porosity Model Construction Based on ANN and Seismic Inversion: A Case Study of Saharan Field (Algeria),” in *Advances in Geophysics, Tectonics and Petroleum Geosciences* (Springer, Cham, 2022), pp. 241–243. doi [10.1007/978-3-030-73026-0_55](https://doi.org/10.1007/978-3-030-73026-0_55).
9. W. Lewis and D. Vigh, “Deep Learning Prior Models from Seismic Images for Full-Waveform Inversion,” *SEG Tech. Program Expand. Abstr.* 2017, 1512–1517 (2017). doi [10.1190/segam2017-17627643.1](https://doi.org/10.1190/segam2017-17627643.1).
10. B. Wu, D. Meng, L. Wang, et al., “Seismic Impedance Inversion Using Fully Convolutional Residual Network and Transfer Learning,” *IEEE Geosci. Remote Sens. Lett.* **17** (12), 2140–2144 (2020). doi [10.1109/LGRS.2019.2963106](https://doi.org/10.1109/LGRS.2019.2963106).



11. V. C. Dodda, L. Kuruguntla, S. Razak, et al., “Seismic Lithology Interpretation Using Attention Based Convolutional Neural Networks,” 2023 3rd Int. Conf. on Intelligent Communication and Computational Techniques (2023), 1–5. doi [10.1109/ICCT56969.2023.10075964](https://doi.org/10.1109/ICCT56969.2023.10075964).
12. Q. Sun, X. Wang, H. Ni, et al., “Fault Identification of U-Net Based on Enhanced Feature Fusion and Attention Mechanism,” *Electronics* **12** (12), Article Number 2562 (2023). doi [10.3390/electronics12122562](https://doi.org/10.3390/electronics12122562).
13. Y.-Q. Wang, Q. Wang, W.-K. Lu, et al., “Seismic Impedance Inversion Based on Cycle-Consistent Generative Adversarial Network,” *Pet. Sci.* **19** (1), 147–161 (2022). doi [10.1016/j.petsci.2021.09.038](https://doi.org/10.1016/j.petsci.2021.09.038).
14. V. Golubev and M. Anisimov, “Application of Convolutional Networks for Localization and Prediction of Scalar Parameters of Fractured Geological Inclusion,” *Int. J. Appl. Mech.* **16** (5), Article Number 2450064 (2024). doi [10.1142/S1758825124500649](https://doi.org/10.1142/S1758825124500649).
15. Y. Zhang and Q. Yang, “An Overview of Multi-Task Learning,” *Natl. Sci. Rev.* **5** (1), 30–43 (2018). doi [10.1093/nsr/nwx105](https://doi.org/10.1093/nsr/nwx105).
16. M. Crawshaw, “Multi-Task Learning with Deep Neural Networks: A Survey,” arXiv:2009.09796v1 [cs.LG] (2020). doi [10.48550/arXiv.2009.09796](https://doi.org/10.48550/arXiv.2009.09796).
17. G. S. Martin, R. Wiley, and K. J. Marfurt, “Marmousi2: An Elastic Upgrade for Marmousi,” *Lead. Edge* **25** (2), 156–166 (2006). doi [10.1190/1.2172306](https://doi.org/10.1190/1.2172306).
18. I. S. Nikitin, N. G. Burago, V. I. Golubev, and A. D. Nikitin, “Continual Models of Layered and Block Media with Slippage and Delamination,” *Procedia Struct. Integr.* **23**, 125–130 (2019). doi [10.1016/j.prostr.2020.01.074](https://doi.org/10.1016/j.prostr.2020.01.074).
19. I. S. Nikitin and V. I. Golubev, “Explicit-Implicit Schemes for Calculating the Dynamics of Layered Media with Nonlinear Conditions at Contact Boundaries,” *J. Sib. Fed. Univ. Math. Phys.* **14** (6), 768–778 (2021). doi [10.17516/1997-1397-2021-14-6-768-778](https://doi.org/10.17516/1997-1397-2021-14-6-768-778).
20. I. B. Petrov, V. I. Golubev, and E. K. Guseva, “Hybrid Grid-Characteristic Schemes for Arctic Seismic Problems,” *Dokl. Akad. Nauk* **501** (1), 67–73 (2021) [*Dokl. Math.* **104** (3), 374–379 (2021)]. doi [10.1134/S1064562421060132](https://doi.org/10.1134/S1064562421060132).
21. O. Ronneberger, P. Fischer, and T. Brox, “U-Net: Convolutional Networks for Biomedical Image Segmentation,” in *Lecture Notes in Computer Science* (Springer, Cham, 2015), Vol. 9351, pp. 234–241. doi [10.1007/978-3-319-24574-4_28](https://doi.org/10.1007/978-3-319-24574-4_28).
22. I. Misra, A. Shrivastava, A. Gupta, and M. Hebert, “Cross-Stitch Networks for Multi-Task Learning,” in *Proc. IEEE Conf. on Computer Vision and Pattern Recognition*, Las Vegas, USA, 2016, pp. 3994–4003. doi [10.1109/CVPR.2016.433](https://doi.org/10.1109/CVPR.2016.433).

Received
October 8, 2024

Accepted for publication
November 28, 2024

Information about the authors

Vasily I. Golubev — Dr. Sci., Professor; 1) Moscow Institute of Physics and Technology, Institutskii pereulok, 9, 141700, Dolgoprudny, Russia; 2) Scientific Research Institute for System Analysis of the National Research Centre “Kurchatov Institute”, Nakhimovsky prospect, 36, building 1, 117218, Moscow, Russia.

Mikhail I. Anisimov — Ph.D. student, Junior Researcher; Moscow Institute of Physics and Technology, Institutskii pereulok, building 9, 141700, Dolgoprudny, Russia.