

Министерство образования и науки Российской Федерации
Федеральное государственное бюджетное образовательное учреждение высшего образования
«Комсомольский-на-Амуре государственный университет»

На правах рукописи

Хряпенко Ксения Дмитриевна

**Разработка информационного модуля,
описывающего поведение материала при
образовании трещин, с помощью искусственного
интеллекта**

Направление подготовки 09.04.03 «Прикладная информатика»

**АВТОРЕФЕРАТ
МАГИСТЕРСКОЙ ДИССЕРТАЦИИ**

Работа выполнена в ФГБОУ ВО
«Комсомольский-на-Амуре государственный университет»

Научный руководитель:

кандидат физико-математических
наук, доцент, заведующая кафедрой
«Прикладная математика»
Григорьева Анна Леонидовна

Рецензент:

кандидат физико-математических
наук, программист высшей категории
отдела мобильных решений ООО
«Индорсофт» Лошманов Антон
Юрьевич

Защита состоится 20 июня 2025 года в 9 часов на заседании государственной экзаменационной комиссии по направлению подготовки 09.04.03 «Прикладная информатика» в Комсомольском-на-Амуре государственном университете по адресу: 681000, г. Комсомольск-на-Амуре, пр. Ленина, 27, ауд. 204/5.

Автореферат разослан 13 июня 2025 г.

Секретарь ГЭК

З.В. Широкова

ОБЩАЯ ХАРАКТЕРИСТИКА ДИСЕРТАЦИОННОЙ РАБОТЫ

Актуальность данного исследования обусловлена малой степенью изученности механизма трещинообразования с помощью элементов машинного обучения, с использованием нейронных сетей, а также большим количеством закрытых данных в области механики твёрдого тела с применением искусственного интеллекта.

Целью дипломной работы состоит в разработке эффективного информационного модуля, использующего методы искусственного интеллекта для описания поведения материала при образовании трещин, позволяющего повысить точность прогнозирования и эффективность вычислений.

Для достижения цели решаются следующие *задачи*:

1. Провести анализ существующих подходов к моделированию поведения материалов при образовании трещин;
2. Исследовать применение искусственных нейронных сетей для решения задач классификации и регрессии при описании поведения материала при трещинообразовании;
3. Провести эксперименты в имитационной среде моделирования MSC.Patran, собрать данные и сформировать набор данных;
4. Создать информационный модуль, интегрирующий ИИ-технологии для прогнозирования поведения материала при образовании трещин.

Объектом исследования являются процессы трещинообразования в материалах под воздействием внешних нагрузок.

Предметом исследования выступают методы искусственного интеллекта, применяемые для анализа и моделирования поведения материалов при образовании трещин.

Научная новизна исследования работы заключается в разработке инновационного подхода к моделированию процесса трещинообразования с использованием современных методов машинного обучения и в определении параметров разрушения материала без использования численных методов и прикладных пакетов

программ. Предложенный информационный модуль позволяет автоматизировать процесс анализа данных, учитывая сложные нелинейные зависимости, что недоступно для традиционных методов. Также реализовано применение нейросетевых архитектур для прогнозирования трещинообразования в реальном времени.

Практическая значимость

Разработанный информационный модуль может быть применен в различных отраслях, таких как строительство, авиастроение и автомобилестроение. Модуль позволяет значительно сократить время на анализ данных и принятие решений, что снижает затраты на проектирование и производство. Кроме того, предложенные методы могут быть интегрированы в существующие программные комплексы для компьютерного моделирования.

Апробация результатов

Результаты работы докладывались на:

- III Всероссийской научно-практической конференции молодых ученых «Наука, инновации и технологии: от идей к внедрению», декабрь 2024 г.;
- VIII Всероссийской национальной научной конференции молодых ученых «Молодежь и наука: актуальные проблемы фундаментальных и прикладных исследований», апрель 2025 г.

Публикации

- Сборник материалов III научно-практической конференции молодых ученых «Наука, инновации и технологии: от идей к внедрению» (Комсомольск-на-Амуре, декабрь 2024 г.);
- Сборник материалов VIII Всероссийской национальной научной конференции молодых ученых «Молодежь и наука: актуальные проблемы фундаментальных и прикладных исследований» (Комсомольск-на-Амуре, апрель 2025 г.).

Государственная регистрация программы для ЭВМ

Свидетельство о регистрации программы ЭВМ. Номер регистрации № 2025664452 от 04.06.2025.

Структура и объем

Магистерская диссертация состоит из введения, трех глав, заключения и списка литературы. Объем работы - 84 страниц, в том числе 68 рисунков и 14 таблиц.

ОСНОВНОЕ СОДЕРЖАНИЕ РАБОТЫ

Введение раскрывает актуальность темы, определяются цели и задачи исследования, объект, предмет, указываются научная новизна, практическая значимость исследования.

В первой главе раскрывается понятие трещинообразования материалов, методы его исследования. Рассматриваются современные подходы к моделированию поведения материалов при образовании трещин.

Исследуется применение искусственного интеллекта для анализа свойств материала. Сравниваются классические методы анализа поведения материалов и современные подходы с использованием ИИ.


Сделан вывод о том, что искусственный интеллект является мощным инструментом в материаловедении, позволяющий решать задачи, которые ранее были недоступны или требовали значительных временных и финансовых затрат. Поэтому, использование ИИ в предсказании поведения материала и анализе его свойств является актуальной задачей материаловедения. Тем не менее, существующие подходы с использованием ИИ также имеют свои ограничения, такие как необходимость больших объемов данных и сложность интерпретации результатов. Эти проблемы мотивируют разработку новых методов, которые могли бы сочетать точность классических подходов с возможностями искусственного интеллекта. Также, производится сравнительный анализ достоинств и недостатков сред имитационного моделирования, на основе которого было решено остановиться на универсальной платформе MSC.Patran для успешного формирования набора данных. В работе была поставлена задача исследования. Рассматривается пластина (таблица 1) с продольным растяжением.

Таблица 1 – Описание основных характеристик пластин


Характеристики		Единицы измерения в MSC.Patran	Система СИ
Длина, a		60 дюймов	1,524 м
Ширина, b		20 дюймов	0,508 м
Высота, c		0,19 дюймов	0,003 м
Диаметр отверстия, d		10 дюймов	0,254 м
Сила, F (пример)		85 фунт/дюйм	378,0987 Н
Напряжение, F (пример)		1 фунт/дюйм ²	6894.76 Па
Модуль эла- стичности, E	Алюминий	$10 \cdot 10^6$ фунт/дюйм ²	68947,6 М Н/м ²
	Сталь	$30 \cdot 10^6$ фунт/дюйм ²	206842,8 М Н/м ²
Коэффициент Пуассона, ν	Алюминий	0,3	
	Сталь	0,25	

В работе предлагается сформировать набор данных в имитационной среде моделирования MSC.Patran и разработать модель ИИ, которая на основе данных о приложенной силе, материале и наличии дефектов определяет пластины с трещинами и предсказывает вероятность их образования у образца.

Во второй главе описывается разработка математической модели и методологии создания набора данных исследования трещинообразования. А именно пошаговый процесс создания пластин в MSC.Patran (рисунок 1), начиная от создания структуры и заканчивая выводом анализа механического нагружения для разных типов образцов (различия по материалу и наличию дефектов, отверстий), также описывается содержание набора данных в виде снимков и табличных данных (рисунок 2). Описывается состав набора данных по материалу, наличию трещин и наличию отверстия (рисунок 3).




а) пластина с отверстием



б) пластина без отверстия

Рисунок 1 – Типы пластин



а) структура снимков

alum_steel_50_50.csv (261.42 kB)


Detail Compact Column

About this file
This file does not have a description yet.

# force сила	# max макс. деформация	# min мин. деформация	Δ mat материал	✓ hole наличие отверстия	✓ crack наличие трещины
34.3k 661k	11m 44.6m	1.92m 2.86m	2 unique values	true false 2000 50%	true false 2000 50%
158488.06148	11831848.799941868	2371222.98668537	alum	no	no
158484.06148	11831844.799941868	2371226.239941867	alum	no	no
158488.06148	11831848.133275198	2371238.239941867	alum	no	no

б) структура таблицы

Рисунок 2 – Структура набора данных




а) содержание набора данных по материалу и наличию трещин




б) разбиение набора данных по наличию отверстия пластин

Рисунок 3 – Содержание набора данных

Производится обработка данных: перевод в систему СИ табличных данных и избавление от «шума» (надписи, стрелки, узлы) на снимках (рисунок 4).




а) пластина с отверстием




б) пластина без отверстия

Рисунок 4 – Обработанные данные


Исследуется влияние наличия дефектов (отверстия), типа материала и приложенной силы на процесс трещинообразования. Выявляются критические силы, с помощью современного метода (рисунок 5, рисунок 6).




а) алюминий без отверстия



б) алюминий с отверстием



в) сталь без отверстия



г) сталь с отверстием

Рисунок 5 – Критическая сила необходимая для образования трещины у материалов


```
plot_graph(material, 'no', material_data) # Без отверстия
```

Критическая сила для пластин из alum с отверстием: 36100

Критическая сила для пластин из alum без отверстия: 152400

Наличие отверстия увеличивает вероятность трещинообразования у пластин из alum в 4.22 раз(а).

Критическая сила для пластин из steel с отверстием: 72500

Критическая сила для пластин из steel без отверстия: 658800

Наличие отверстия увеличивает вероятность трещинообразования у пластин из steel в 9.09 раз(а).

Рисунок 6 – Результат работы программы

Наличие дефекта у пластин (наличие отверстия) уменьшает критическую силу и увеличивает риск образования трещин у материала. А именно, у пластин из стали наличие отверстия увеличивает вероятность трещинообразования в 9,09 раз, а у пластин из алюминия в 4,22 раза. Очевидно, влияние типа материала на различие в критических силах, необходимых для образования трещин. Это обусловлено рядом факторов, связанных с физико-математическими свойствами (различия в модуле упругости и прочностных характеристиках материала).

Сравниваются современный и традиционный (аналитический) подходы. Расчет критических сил (таблица 2) проводился по следующим формулам, исходя из характеристик, приведенных в таблице 1:

1. Пластина без отверстия:

$$F_{\text{крит}} = \sigma_{\text{в}} \cdot b \cdot c, \quad (1)$$

где $\sigma_{\text{в}}$ – предел прочности материала; b – ширина пластины; c – толщина пластины.

2. Пластина с отверстием:

$$F_{\text{крит}} = \frac{K_{IC}}{\sqrt{\pi \cdot \frac{d}{2}}} \cdot (b - d) \cdot c, \quad (2)$$

где K_{IC} – вязкость разрушения материала; d – диаметр отверстия.

Таблица 2 – Расчет критических сил материалов

Характеристики		MSC.Patran	Формулы (1) и (2)
Критическая сила, $F_{\text{крит}}$	Алюминий с отверстием	36100 Н	36,1 кН
	Алюминий без отверстия	152399 Н	152,4 кН
	Сталь с отверстием	72500 Н	72,5 кН
	Сталь без отверстия	658800 Н	658,8 кН

Было установлено (таблица 2), что критическая сила, приложенная для об-

разования трещин в среде имитационного моделирования MSC.Patran, совпадает с критической силой, рассчитанной по формулам (1) и (2), что говорит о достоверности сформированного набора данных.

В третьей главе производится разработка алгоритмов с внедрением машинного обучения для анализа трещинообразования.

Исходя из анализа методов бинарной классификации и регрессии, было решено остановиться на нейронных сетях, так как этот метод больше всего удовлетворяет целям и задачам исследования.

На основе выше пересиленного, можно сделать вывод о том, что нельзя отрицать возможность будущего расширения набора данных за счет введения новых материалов, дефектов (например, увеличение числа отверстий в образце) и параметров, таких как размер трещины и тип деформации, влияющих на образование трещин у пластин. Нейронные сети способны справиться с такими большими объемами набора данных.

При рассмотрении модели на отдельных категориях простая нейронная сеть с двумя свёрточными слоями дала позитивные результаты при оценке качества работы.

При обучении модели на разных уровнях эпох последовательно увеличивается точность и уменьшается ошибка (потери) для каждой из категорий. Данный метод не подходит для внедрения в информационный модуль, так как каждая из моделей является отдельным решением.

Необходимо создать единую модель, отвечающую всем параметрам исследования. Для этого за основу были взяты модели, представленные ранее (рисунок 7).

Была разработана новая модель на основе полносвязной нейронной сети с одним скрытым слоем (использование *Keras* (часть *TensorFlow*)) (рисунок 7б).




Рисунок 7 – Архитектура нейронных сетей

Главными отличиями новой модели стали: применение SMOTE для балансировки классов, создание кастомного классификатора, добавление поиска лучших параметров модели с помощью GridSearchCV для их перебора и обучение на их основе, а также оптимизация порогового значения (позволяет более точно классифицировать входящие данные) и добавление новых признаков (для лучшего понимания их взаимодействия).

В данном алгоритме (рисунок 7б) используются различные математические и статистические формулы, которые применяются в процессе обработки данных, обучения моделей и оценки их производительности.

Ниже приведена математическая модель, которая явно или неявно использует данные формулы.

Выпишем целевую функцию (3) и систему ограничений (4), это и будет математической моделью.

Целевая функция (3) минимизирует бинарную кросс-энтропию. Условия (4) гарантируют корректность данных, параметров модели, процесса обучения и предобработки.

$$L(\theta) = -\frac{1}{N} \sum_{i=1}^N [y_i \cdot \log(\hat{y}_i) + (1 - y_i) \cdot \log(1 - \hat{y}_i)] \rightarrow \min. \quad (3)$$

$$\left\{ \begin{array}{l} y_i \in \{0,1\}, \hat{y}_i \in (0,1), X \in \mathbb{R}^{N \times d} \\ z_{ij} = \frac{x_{ij} - \mu_j}{\sigma_j} \in Z \in \mathbb{R}^{N \times d}, \forall i \in [1; N], \forall j \in [1; d] \\ \mu_j = \frac{1}{N} \cdot \sum_{i,j} x_{ij}, \sigma_j = \sqrt{\frac{1}{N} \sum_{i,j} (x_{ij} - \mu_j)^2}, \forall i \in [1; N], \forall j \in [1; d] \\ X' \in \mathbb{R}^{N \times d'}, d' > d \\ h^{(1)} = \text{ReLU}(W^{(1)} \cdot x'_i + b^{(1)}), W^{(1)} \in \mathbb{R}^{128 \times d'}, b^{(1)} \in \mathbb{R}^{128} \\ \widetilde{h}^{(1)} = \text{Dropout}(h^{(1)}, p) \\ h^{(2)} = \text{ReLU}(W^{(2)} \cdot \widetilde{h}^{(1)} + b^{(2)}), W^{(2)} \in \mathbb{R}^{64 \times 128}, b^{(2)} \in \mathbb{R}^{64} \\ \widetilde{h}^{(2)} = \text{Dropout}(h^{(2)}, p) \\ \hat{y}_i = \sigma(W^{(3)} \cdot \widetilde{h}^{(2)} + b^{(3)}), W^{(3)} \in \mathbb{R}^{1 \times 64}, b^{(3)} \in \mathbb{R} \\ \nabla_{\theta} L(\theta) \exists, \eta > 0, \beta_1, \beta_2 \in (0,1) \\ t^* = \arg \max_t \left(2 \cdot \frac{\text{Precision}(t) \cdot \text{Recall}(t)}{\text{Precision}(t) + \text{Recall}(t)} \right), t \in [0,1] \end{array} \right. , \quad (4)$$

где $\theta = \{W^{(l)}, b^{(l)}\}$; N – количество объектов; d – количество признаков; $y_i = 1$, если объект принадлежит к классу «трещины»; $y_i = 0$, если объект не принадлежит к классу «трещины»; x_{ij} – значение i -го признака для j -го объекта; μ_j – среднее значение j -го признака; σ_j – стандартное отклонение j -го признака; z_{ij} – нормализованное значение; Z – нормализованная матрица; X' – расширенная матрица признаков; l – номер слоя ($l = \overline{1, L}$); $h^{(l)}$ – выход l -го слоя; $W^{(l)}$ – матрица весов размерности $(n_{out}^{(l)}, n_{in}^{(l)})$; $b^{(l)}$ – вектор смещений размерности $(n_{out}^{(l)})$; $\widetilde{h}^{(l)}$ – случайным образом обнуляет часть нейронов ($h_j^{(l)}$ с вероятностью $1 - p$ или 0 с вероятностью p); σ – функция активации (сигмоида); y_i – истинное значение (0 или 1); $\hat{y}_i$ – предсказанное значение (вероятность); η – скорость обучения (*learning rate*); $\nabla_{\theta} L(\theta)$ – градиент функции потерь.

Результаты тестирования модели являются ожидаемыми. Модель демонстрирует хорошую точность ($Accuracy \approx 0,9425$) (рисунок 8).

```

Best Parameters: {'batch_size': 32, 'dropout_rate': 0.2, 'epochs': 50, 'optimizer': 'adam'}
25/25 — 0s 1ms/step
Optimal Threshold: 0.5044
AUC-ROC: 0.9425
Confusion Matrix:
[[377  23]
 [ 43 357]]
Classification Report:

```

	precision	recall	f1-score	support
0	0.90	0.94	0.92	400
1	0.94	0.89	0.92	400
accuracy			0.92	800
macro avg	0.92	0.92	0.92	800
weighted avg	0.92	0.92	0.92	800

Рисунок 8 – Результаты обучения новой модели

Далее рассматривается модель распознавания трещин у снимков пластин разных материалов, а именно, описывается математическая модель алгоритма в виде целевой функции (5) и системы ее ограничений (6).

$$J(\Theta) = -\frac{1}{N} \sum_{i=1}^N \sum_{k=1}^K y_{ik} \log(\widehat{y}_{ik}) + \lambda \sum_{l=1}^L \|W_l\|_F^2 \rightarrow \min, \quad (5)$$

где N – количество изображений в батче; K – количество классов; y_{ik} – истинная метка для i -го изображения и k -го класса; $\widehat{y}_{ik}$ – предсказанная вероятность для i -го изображения и k -го класса; W_l – матрица весов l -го слоя; $\|W_l\|_F^2$ – квадрат нормы Фробениуса матрицы весов; λ – коэффициент регуляризации.

$$\left\{ \begin{array}{l} H \times W \times C = 128 \times 128 \times 3 \\ x_{norm} = \frac{x_{i,j,c}}{255} \\ K_h \times K_w = 3 \times 3, F = [32, 64, 128] \\ P_h \times P_w = 2 \times 2 \\ D = H''' \times W''' \times F_L \\ M = 512, K = 4 \\ B = 32, E = 20, \eta = 0.0001, \lambda = 0.0001 \end{array} \right., \quad (6)$$

где B – размер батча; E – количество эпох; η – скорость обучения.

Данная модель представляет собой сверточную нейронную сеть, которая состоит из нескольких слоев, включая свертки, пуллинг, полносвязные слои и регуляризацию. Архитектура модели представлена на рисунке 9.




Рисунок 9 – Архитектура модели классифицирования трещинообразования у снимков

Далее описывается тестирование и результаты модели на снимках пластин (рисунок 10 – рисунок 13).

Model: "sequential"

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 126, 126, 32)	896
max_pooling2d (MaxPooling2D)	(None, 63, 63, 32)	0
conv2d_1 (Conv2D)	(None, 61, 61, 64)	18,496
max_pooling2d_1 (MaxPooling2D)	(None, 30, 30, 64)	0
conv2d_2 (Conv2D)	(None, 28, 28, 128)	73,856
max_pooling2d_2 (MaxPooling2D)	(None, 14, 14, 128)	0
flatten (Flatten)	(None, 25088)	0
dense (Dense)	(None, 512)	12,845,568
dropout (Dropout)	(None, 512)	0
dense_1 (Dense)	(None, 4)	2,052

Рисунок 10 – Описание параметров модели для каждого типа слоя

Total params: 12,940,868 (49.37 MB)
Trainable params: 12,940,868 (49.37 MB)
Non-trainable params: 0 (0.00 B)

Рисунок 11 – Входящие параметры

```

AUC-ROC: 0.8451
Confusion Matrix:
[[239 161]
 [ 1 399]]
Classification Report:

```

	precision	recall	f1-score	support
0	1.00	0.60	0.75	400
1	0.71	1.00	0.83	400
accuracy			0.80	800
macro avg	0.85	0.80	0.79	800
weighted avg	0.85	0.80	0.79	800

Рисунок 13 – Отчет по классификации снимков

Таким образом, модель демонстрирует логичное и ожидаемое поведение, что подтверждает ее надежность и полезность для задач прогнозирования трещинообразования. Точность классификации изображений пластин равна 0,8.

В четвертой главе говорится о создании информационного модуля для прогнозирования вероятности трещинообразования у материалов, с внедрением модели многослойного перцепторна с двумя скрытыми слоями и сигмои-дальной активацией на выходе, а также модели на основе свёрточной нейрон-ной сети для распознавания трещин у снимков пластин (рисунок 14).

Анализ пластины

Исходные данные пластины

Материал:

Наличие отверстия:

Сила:

Критическая сила: 72500

Анализ нейронной сети: Трещины нет

Снимок пластины

Результаты

	Исходные данные	Снимок	Итого
Вероятность трещинообразования	33%	0%	33%

Рисунок 14 – Информационный модуль для прогнозирования поведения материала

В *заключении* приводятся основные результаты исследований, анализ, полученных результатов и возможности их дальнейшего улучшения.

СПИСОК ПУБЛИКАЦИЙ ПО ТЕМЕ ИССЛЕДОВАНИЯ

1 Хряпенко, К. Д. Проблематика определения материала образца в механике деформируемого твердого тела с помощью применения искусственного интеллекта / К. Д. Хряпенко, А. Л. Григорьева // Наука, инновации и технологии: от идей к внедрению : Материалы III Всероссийской научно-практической конференции молодых ученых, Комсомольск-на-Амуре, 11–12 декабря 2024 года. – Комсомольск-на-Амуре: Комсомольский-на-Амуре государственный университет, 2025. – С. 237-240. – EDN BLFSAR.

2 Хряпенко, К. Д. Формирование датасета при исследовании поведения материала с использованием MSC.Patran для моделирования трещинообразования / К. Д. Хряпенко, А. Л. Григорьева // Молодежь и наука: актуальные проблемы фундаментальных и прикладных исследований : Материалы VIII Всероссийской национальной научной конференции молодых ученых, Комсомольск-на-Амуре, 7–11 апреля 2025 года. – Комсомольск-на-Амуре: Комсомольский-на-Амуре государственный университет, 2025. – С. 604-607.

3 Хряпенко, К. Д. Решение задач классификации и регрессии при исследовании поведения материала при трещинообразовании / К. Д. Хряпенко, А. Л. Григорьева // Молодежь и наука: актуальные проблемы фундаментальных и прикладных исследований : Материалы VIII Всероссийской национальной научной конференции молодых ученых, Комсомольск-на-Амуре, 7–11 апреля 2025 года. – Комсомольск-на-Амуре: Комсомольский-на-Амуре государственный университет, 2025. – С. 600-603.