

- 23 Оценка коэффициента корреляции. Вырабатываемый навык – оценка коэффициента корреляции.  
 24 Критерий Кочрена. Вырабатываемый навык – сравнение дисперсий по критерию Кочрена.  
 25 Критерий Манна – Уитни. Навык – сравнение средних по критерию Манна – Уитни.  
 26 Критерий Фишера. Вырабатываемый навык – использование однофакторного анализа.  
 27 Информация. Вырабатываемый навык – вычисление информации в простейших задачах.  
 28 Случайные процессы и временные ряды. Вырабатываемый навык – отыскание математического ожидания и дисперсии временного ряда.  
 29 Автокорреляционная функция случайного процесса. Вырабатываемый навык – отыскание автокорреляционной функции временного ряда.  
 30 Обзорное занятие.

Затем студентам выдаются индивидуальные задания, похожие на то, которое разобрал преподаватель. Для получения зачета необходимо выполнить все задания.

Теоретические основы курса и примеры использования получаемых знаний для решения задач, возникающих в транспортной отрасли, изложены, например, в работах [1–5]. В частности, учебное пособие [5] издано в нашем университете, и основными примерами, которые в нем разбираются, являются примеры из практики железнодорожного транспорта.

#### Список литературы

- 1 Гмурман, В. Е. Руководство к решению задач по теории вероятностей и математической статистике / В. Е. Гмурман. – М. : Высш. шк., 2014. – 400 с.
- 2 Коротких, Ю. С. Моделирование транспортных процессов / Ю. С. Коротких, Н. Н. Пуляев. – М. : Автограф, 2019. – 150 с.
- 3 Вельможин, А. В. Основы теории транспортных процессов и систем : учеб. пособие для вузов / А. В. Вельможин, В. А. Гудков, Л. Б. Миротин. – М. : Академия, 2008. – 288 с.
- 4 Математическое моделирование транспортных систем и процессов / А. Н. Рахмангулов. – Магнитогорск : МГТУ им. Г. И. Носова, 2021. – 190 с.
- 5 Карпухин, В. Б. Теория и практика математического моделирования в задачах транспортной системы / В. Б. Карпухин. – М. : РУТ (МИИТ), 2021. – 111 с.

УКД 539.31

## ПРИМЕНЕНИЕ ТЕХНОЛОГИЙ ГЛУБОКОГО МАШИННОГО ОБУЧЕНИЯ И ФИЗИЧЕСКИ ИНФОРМИРОВАННЫХ НЕЙРОННЫХ СЕТЕЙ В РЕШЕНИИ ОБРАТНЫХ НЕСТАЦИОНАРНЫХ ЗАДАЧ ПО ИДЕНТИФИКАЦИИ ФИЗИКО-МЕХАНИЧЕСКИХ СВОЙСТВ ДЛЯ БАЛКИ БЕРНУЛЛИ – ЭЙЛЕРА

*Я. А. ВАХТЕРОВА*

*Московский авиационный институт (НИИ), Российская Федерация  
НИИ механики МГУ им. М. В. Ломоносова, г. Москва, Российская Федерация*

*И. П. КОЗЛОВ*

*Московский авиационный институт (НИИ), Российская Федерация*

*Г. В. ФЕДОТЕНКОВ*

*Московский авиационный институт (НИИ), Российская Федерация  
НИИ механики МГУ им. М. В. Ломоносова, г. Москва, Российская Федерация*

В данной работе рассматривается однородная изотропная шарнирно опертая балка Бернулли – Эйлера конечной длины. На балку воздействует нестационарная сосредоточенная сила. В прямой задаче, зная физико-механические свойства, требуется определить прогиб балки, в обратной: зная показания ускорений с датчика – модуль Юнга и площадь поперечного сечения. На первом этапе задача решается численно-аналитически. Это требуется для проверки результатов, полученных с помощью технологий глубокого машинного обучения и физически информированных нейронных сетей (PINN). На втором этапе строится физически информированная нейронная сеть.

С каждым годом всё чаще появляются новые материалы, которые требуют определения точных свойств (модуля Юнга и модуля сдвига). Обычно модуль упругости определяется с помощью механических испытаний, таких как эксперименты по одноосному растяжению, которые проводятся на специально подготовленных образцах, соответствующих протоколам тестирования. Этот подход

включает сбор данных о напряжении и предположение о феноменологической конститутивной модели материала. Тем не менее эта традиционная система требует строгого процесса подготовки образцов, а также экономических затрат.

Для решения прямых и обратных нестационарных задач механики деформируемого твердого тела используются два подхода. Первый подход основан на аналитических либо численно-аналитических решениях прямой и обратной задачи с помощью метода функций влияния. Второй подход реализован с применением технологий глубокого машинного обучения и физически информированных нейронных сетей. Он позволит построить решения новых нестационарных прямых и обратных задач, которые ранее аналитически получить было крайне сложно или невозможно.

В первом подходе аналитические и численно-аналитические решения обратных задач строятся с использованием функций влияния (фундаментальных решений, функций Грина). При этом сначала аналитическими методами строится функция влияния для прямой задачи. Они являются решениями задач о воздействии на рассматриваемое тело сосредоточенных во времени и по координатам нагрузок. При этом они разделяются на граничные функции влияния (в случае, когда сосредоточенная нагрузка входит в правую часть граничных условий) и объёмные функции влияния (когда сосредоточенные нагрузки содержатся в правых частях дифференциальных уравнений движения). Для математического описания таких нагрузок используется аппарат обобщённых функций. Функции влияния также являются обобщёнными и, в отличие от обычных функций перемещений или напряжений (внутренних усилий), могут иметь разрывы и даже более сильные особенности. Функции влияния строятся с применением интегрального преобразования Лапласа по времени, а также с применением разложений в ряды по системам собственных функций для прямой задачи. Обращение интегрального преобразования Лапласа по времени будет реализовано с привлечением теории вычетов. С использованием функций влияния построены интегральные представления решений прямых задач. В случае обратных задач с использованием этих интегральных представлений получены разрешающие интегральные уравнения для обратных задач. Разрешающие интегральные уравнения кроме внешних нагрузок содержат также и все параметры модели: плотность материала, упругие константы, геометрические параметры. В различных постановках часть параметров модели или внешние нагрузки являются искомыми неизвестными, которые требуется определить из решения обратной задачи, сводящейся к указанным разрешающим уравнениям. Для решения обратных задач с помощью описанного выше подхода, сводящегося к решению интегральных уравнений, используется метод механических квадратур в сочетании с быстрым преобразованием Фурье. В случае наличия сильных особенностей в ядрах интегральных операторов построены специальные квадратурные формулы, основанные на методе канонической регуляризации с аналитическим выделением особенностей. Преимуществом этого подхода является то, что он приводит интегральные уравнения первого рода, решение которых может оказаться некорректной задачей, к интегральным уравнениям второго рода.

Следует отметить, что описанные выше подходы к решению обратных задач могут быть применены в тех случаях, когда исходные задачи являются линейными (дифференциальные операторы, входящие в уравнения и граничные условия, являются линейными). Если эти условия нарушаются, то предложенные выше методы решения оказываются бессильными. Для этих случаев предполагается развитие и применение нейросетевых технологий, с использованием искусственных нейронных сетей с физическим подкреплением (физически информированных нейронных сетей) и алгоритмов глубокого машинного обучения. В этом случае для аппроксимации искомым функций и параметров используется нейронная сеть. Благодаря своей универсальности при использовании в качестве «аппроксиматоров» нейронные сети могут быть с успехом применены к решению как прямых, так и обратных задач математической физики, причем и линейных, и нелинейных.

Физически информированные нейронные сети (ФИНС) в сочетании с алгоритмами их обучения, которые по сути являются градиентными методами математической оптимизации, могут быть использованы для решения прямых и обратных задач, в том числе с зашумленными экспериментальными наблюдениями данными. Поскольку ФИНС могут использовать известные данные, придерживаясь любых заданных физических законов, выраженных в математической постановке задачи (уравнения, начальные и граничные условия, дополнительные данные), их можно отнести к классу нейронных сетей, которые решают задачи обучения с учителем. ФИНС могут применяться к решению дифференциальных уравнений и начально-краевых задач, имеющих наиболее общую форму:

дифференциальные уравнения могут быть линейными или нелинейными, граничные условия могут являться условиями Дирихле, Неймана, смешанными или периодическими. Уравнения и соотношения математической постановки могут описывать разнообразные физические системы, включая как прямые, так и обратные задачи механики деформируемого твёрдого тела. При этом как прямая, так и обратная задача рассматриваются в рамках одной нейросетевой модели – с помощью подхода, основанного на использовании ФИНС, обе проблемы могут быть решены «за один проход», т. е. в рамках одного цикла обучения (оптимизации). В таком контексте основная цель – «научить» нейронную сеть аппроксимировать заданные дифференциальные уравнения, начальные, граничные условия и дополнительные соотношения (в случае обратной задачи) путем определения матриц весов и векторов смещений нейронной сети, приводящих к минимизации функции потерь, которая представляет собой сумму невязок (возможно, взвешенную), включающую невязки всех уравнений, начальных и граничных условий, а также дополнительных соотношений, составляющих математическую постановку задачи. Именно построение такой специальной функции потерь, которая включает в себя полную информацию о математической модели, отличает ФИНС от других типов нейронных сетей. В то же время сама математическая модель и является «учителем» для нейронной сети. Таким образом, нет необходимости в огромных базах тренировочных и проверочных наборов данных, которые необходимы, например, для обучения нейронной сети распознаванию образов или речи. Иными словами, такая нейронная сеть «заранее знает», чему она должна обучиться.

Впоследствии физико-механические свойства материала могут быть определены путем сопоставления экспериментальных данных или аналитических решений с предполагаемым методом глубокого машинного обучения и физически информированных нейронных сетей.

*Работа выполнена при поддержке гранта РФФ № 20-19-00217, <https://rscf.ru/project/20-19-00217>.*

УДК 539.3

## **ИССЛЕДОВАНИЯ НЕСУЩЕЙ СПОСОБНОСТИ ОРТОТРОПНЫХ ПЛАСТИН С ПРЯМЫМИ И ЗЕНКОВАННЫМИ ОТВЕРСТИЯМИ**

*В. А. ВЕСТЯК*

*Московский авиационный институт (НИУ), Российская Федерация*

*Е. И. СМАГИН*

*ПАО «Яковлев», г. Москва, Российская Федерация*

*М. И. МАРТИРОСОВ*

*Московский авиационный институт (НИУ), Российская Федерация*

Интенсивное внедрение ортотропных материалов в различных областях промышленности показывает большой потенциал полимерных композиционных материалов (ПКМ) по показателям прочности и весовой эффективности. Применение ПКМ сопровождается исследованиями свойств материала и конструкции в местах соединений. В работе представлены результаты расчетно-экспериментальных исследований прочности ортотропных пластин со свободным и нагруженным отверстиями. Рассмотрены различные методы испытаний для образцов, моделирующих работу конструкции с проходящей и сминающей нагрузкой, а также образцы, моделирующие совместное действие указанных выше нагрузок. Для различных методов испытаний представлены виды образцов, схемы нагружения. На образцах со свободным и нагруженным отверстиями проведены экспериментальные исследования напряженно-деформированного состояния (НДС) и остаточной прочности ПКМ на основе эпоксидной матрицы и высокомодульного волокна.

Для экспериментальной оценки несущей способности в ортотропных пластинах с концентраторами в виде свободных отверстий и отверстиями с зенковкой проводится статическое нагружение образцов со схожей схемой армирования. Испытания проводились в соответствии с существующими стандартами, представленными в ГОСТ 33498–2015, ГОСТ Р 56788–2015 и ГОСТ 33375–2015.