

О нейросетевых моделях деформирования тонкостенных оболочек

Ю. Н. Згода

Санкт-Петербургский государственный архитектурно-строительный университет, Санкт-Петербург, Россия

yurii.zgoda@mail.ru

Аннотация. Компьютерное моделирование тонкостенных оболочечных конструкций представляет собой длительный и ресурсоемкий процесс, особенно в тех случаях, когда исследователю необходимо реализовать оригинальное программное обеспечение моделирования оболочек. К наиболее перспективным направлениям, позволяющим в значительной степени повысить производительность моделирования конструкций этого типа и упростить разработку программного обеспечения, относится их нейросетевое моделирование. Ввиду новизны данного подхода его свойства и особенности практического применения остаются малоизученными.

Целью данной статьи служит классификация и анализ особенностей различных подходов к формированию нейросетевых моделей деформирования оболочечных конструкций. В рамках реализации этой цели был проведен литературный обзор современных исследований, посвященных применению нейросетевого моделирования в различных научных областях, в том числе в области моделирования оболочек и плит (которые можно рассматривать как частный случай оболочек). На основе результатов обзора и оригинальных исследований предложена система классификации нейросетевых моделей деформирования оболочек по трем направлениям с описанием преимуществ и недостатков каждого из подходов. Введение подобной классификации упрощает выбор между различными архитектурами нейросетей и источниками данных для обучения, а также позволяет структурировать существующие знания по этой теме.

Для одной из рассмотренных нейросетевых архитектур был проведен вычислительный эксперимент с описанием процедуры подготовки обучающего набора данных, обучения и валидации сети, приведены результаты анализа ее свойств. Выделены наиболее перспективные для последующего исследования подвиды нейросетевых моделей деформирования оболочек. Показана высокая эффективность нейросетевого моделирования в отношении как производительности, так и точности моделирования.

Ключевые слова: оболочки, нейросетевое моделирование, Julia, Flux, высокопроизводительные вычисления, классификация, вычислительный эксперимент

Для цитирования: Згода Ю. Н. О нейросетевых моделях деформирования тонкостенных оболочек // Изв. СПбГЭТУ «ЛЭТИ». 2025. Т. 18, № 1. С. 55–70. doi: 10.32603/2071-8985-2025-18-1-55-70.

Original article

Neural Network Models of Deformation of Thin-Walled Shells

Iu. N. Zgoda

Saint Petersburg State University of Architecture and Civil Engineering,
Saint Petersburg, Russia

yurii.zgoda@mail.ru

Abstract. Computer simulation of thin-walled shell structures is a time- and resource-intensive process, especially in those cases when the researcher needs to implement original modeling software. Neural network modeling is a promising approach that can significantly increase modeling performance of such constructions and simplify software development is neural network modeling. Due to the novelty of this approach, its practical application features remain underexplored.

In this work, we aim to classify and analyze various approaches to creation of neural network models for describing the deformation of shell structures. To that end, we carry out a literature review of modern studies devoted to the application of this approach in various scientific fields, including modeling shells and plates (which can be considered as a special case of shells). On the basis of the conducted literature review, a system for classifying neural network models of shell deformation is proposed. This system includes three directions with a description of advantages and disadvantages of each of the mentioned approaches. The introduction of such a classification system simplifies the process of selecting neural network architectures and training data sources. In addition, the system represents the existing scientific knowledge in a structured manner.

For one of the considered neural network architectures, a computational experiment is carried out with the description of training data preparation, network training, and validation procedures. The analytical properties of the architecture are presented. The most promising subtypes of neural network shell models requiring further research are identified. The high efficiency of neural network research in terms of performance and accuracy is noted.

Keywords: shells, neural network modeling, Julia, Flux, high-performance computing, classification, computational experiment

For citation: Zgoda Iu. N. Neural Network Models of Deformation of Thin-Walled Shells // LETI Transactions on Electrical Engineering & Computer Science. 2025. Vol. 18, no. 1. P. 55–70. doi: 10.32603/2071-8985-2025-18-1-55-70.

Введение. Тонкостенные оболочечные конструкции (оболочки) – это криволинейные конструкции, у которых один из размеров (толщина) значительно меньше двух других. Такие конструкции отличаются разнообразием форм, высокой прочностью и жесткостью, а также тем, что для них при нагружении потеря устойчивости в большинстве случаев наступает раньше, чем потеря прочности [1].

Сейчас в качестве подхода к изучению свойств оболочек наиболее распространен физический эксперимент [2], [3], математическое [4], [5] и компьютерное моделирование [6]–[8]. В данной статье рассматривается относительно новый подход к моделированию оболочек – нейросетевое моделирование. Суть его заключается в обучении нейронной сети на некотором наборе данных, описывающем поведение разных конфигураций оболочек под воздействием внешних сил. Такая нейросеть способна с высокой точностью моделировать напряженно-деформированное состояние (НДС) конструкции при произвольных ее параметрах.

Нейросетевое моделирование можно рассматривать как компьютерное моделирование, в том смысле, что обучение нейросети моделирования НДС оболочки и последующий расчет конструкций через нейросеть реализуется на компьютере. С другой стороны, при таком моделировании не проводится решение систем линейных или нелинейных алгебраических уравнений, реализация каких-либо численных методов и т. д. Кроме того, вычисления с использованием нейросети имеют константную асимптотическую сложность, в то

время как классические методы моделирования обычно имеют нелинейную асимптотику.

Нейросеть, решающую задачу регрессии, в случае отсутствия в ней рекуррентных соединений, можно также рассматривать как регрессионную модель [9], которая, в свою очередь, есть математическая модель [10]. Это связано с тем, что и нейросеть, и регрессионная модель представляют собой некоторые функции, для которых необходимо определить ряд неизвестных параметров. После определения этих параметров они позволяют с определенной точностью описывать зависимость между входными и выходными данными.

Постановка задачи. Целью данной статьи является классификация и анализ особенностей различных подходов к формированию нейросетевых моделей деформирования оболочечных конструкций. Для ее реализации были поставлены следующие задачи:

- провести классификацию и сравнительный анализ существующих подходов к нейросетевому моделированию оболочек;
- описать процедуру формирования обучающего набора данных;
- описать процедуру обучения нейросетевой модели деформирования цилиндрической оболочки;
- провести вычислительные эксперименты с использованием оригинальной нейросетевой модели для оценки точности и длительности нейросетевого моделирования в сравнении с классическим компьютерным моделированием.

Классификация нейросетевых моделей. В рамках данной статьи под нейросетевым моделированием имеется в виду применение нейросе-

ти, способной описывать поведение множества различных конфигураций конструкций. Такой подход отличается от использования нейронных сетей с физической информацией (*англ.* Physically-Informed Neural Networks, PINN) [11]–[12], хотя стоит отметить, что он успешно применяется в моделировании оболочек [13]. В PINN нейросеть представляет собой решение одной конкретной задачи, в то время как рассматриваемый в данной статье подход предполагает моделирование целого класса конструкций. По аналогичной причине здесь не рассматривается применение метода DeepRitz [14].

При еще более общей постановке задачи, а именно при рассмотрении других методов машинного обучения, помимо глубокого обучения актуальным направлением представляется применение деревьев решений в контексте расчета НДС оболочек. На данный момент исследования подобного вида еще более малочисленны, чем исследования в области нейросетевого моделирования оболочек, однако они демонстрируют высокую эффективность применения данного подхода. Например, в [15] авторам удалось успешно оптимизировать конфигурацию многослойных композитных цилиндрических оболочек, а в [16] демонстрируется высокая эффективность применения деревьев решений при определении критической нагрузки торисферических элементов. И хотя данная публикация посвящена непосредственно глубокому обучению в контексте моделирования НДС оболочек, применение деревьев решений – перспективное направление для последующих исследований.

При нейросетевом моделировании оболочек в качестве входных данных используются параметры, описывающие моделируемую оболочку (т. е. физические и геометрические характеристики), а в качестве выходных – искомые характеристики конструкции (такие, как критическая нагрузка или соответствующий ей прогиб). По результатам проведенного литературного обзора были разработаны два основных способа классификации методов нейросетевого моделирования:

– классификация по источнику обучающих данных: они могут быть получены в результате вычислительного эксперимента («синтетические» данные) или физических экспериментов;

– классификация по выходным данным: скалярные (результатом моделирования служит одна или несколько характеристик конструкции) и непрерывные (когда нейросеть может описать НДС

конструкции при конкретном нагружении в определенной ее точке).

Использование результатов физических экспериментов возможно в том случае, когда имеется обширный набор экспериментальных данных. Например, в [17] авторы использовали результаты 38 различных исследований, в общей сложности содержащие 516 описаний оболочечных конструкций. Обученная авторами нейросеть обладала значительно меньшей погрешностью моделирования по сравнению с формулами, представленными в проектировочных рекомендациях NASA и EC-3.

Обучение на результатах физического моделирования избавляет исследователя от необходимости построения математической модели как таковой. С другой стороны, для использования этого подхода необходимо располагать большим объемом информации о поведении различных конструкций под воздействием внешних сил.

Альтернативный подход заключается в использовании результатов вычислительных экспериментов для обучения нейронной сети. Компьютерное моделирование гораздо проще в реализации по сравнению с проведением физических экспериментов, из-за чего этот подход более распространен в современных исследованиях. Так, в [18] для нейросетевого моделирования плит (частного случая оболочек) с ребрами жесткости было использовано конечно-элементное моделирование. Обученная нейросеть была способна с достаточной точностью определять критическую нагрузку конструкции по ее параметрам, при этом длительность вычислений была значительно меньше в сравнении с использованным авторами конечно-элементным программным обеспечением (ПО).

При обучении на синтетических данных нейросетевая модель перенимает свойства модели, лежащей в основе используемого для генерации результатов вычислений программного обеспечения. Главная особенность такой нейросетевой модели заключается не в повышенной точности, а в значительно более высокой скорости моделирования. Такая нейросеть по определению не может быть точнее, чем ПО, через которое были сгенерированы обучающие данные. Прирост производительности обусловлен тем, что при ее использовании не требуется решения систем линейных или нелинейных алгебраических уравнений, минимизации многомерных функций или каких-либо других ресурсоемких вычислений.

Второе предлагаемое направление для классификации – классификация по выходным данным нейросети. В рассмотренных ранее исследованиях нейросеть определяла критическую нагрузку конструкции, т. е. некоторую единичную характеристику. Однако во многих исследованиях необходимо получить не только критическую нагрузку, но и НДС конструкции под воздействием произвольной нагрузки и для произвольной области этой конструкции. Таким образом, возможны архитектуры нейросетей моделирования оболочек, описывающие одну или несколько обобщающих конструкцию характеристик (далее – скалярные нейросетевые модели) и архитектуры, выполняющие более детальное моделирование конструкции в каждой ее точке под воздействием различных внешних сил (далее – непрерывные нейросетевые модели).

Непрерывные нейросетевые модели представляют собой более эффективный инструмент исследования, способный решать более широкий спектр задач в сравнении со скалярными моделями. С другой стороны, непрерывная нейросеть будет включать в себя больше параметров, а для ее обучения потребуются большой объем входных данных. Если одной конструкции при скалярной модели соответствует один выходной вектор, то для непрерывной модели их могут быть десятки и сотни, так как одной конструкции соответствуют результаты моделирования при разных значениях прикладываемой нагрузки в разных точках конструкции.

На данный момент работы, посвященные непрерывным нейросетевым моделям оболочек, единичны. В области моделирования плит была обнаружена одна публикация [19], в которой описывается несколько нейросетей моделирования напряженно-деформированного состояния плит. Для формирования обучающего набора данных ее авторы использовали результаты конечно-элементного моделирования.

Другая возможная вариация при разработке нейросетевых моделей заключается в выборе между размерными и безразмерными обучающими данными. Существуют специальные математические модели оболочек, для которых решение задачи описывает поведение не одной конкретной конструкции, а целого класса подобных друг другу конструкций. В то же время, определение диапазона данных по каждому из входных параметров нейросети при использовании безразмерных параметров представляет собой нетривиальную задачу. Чтобы решить эту проблему, предлагается

«компромиссный» вариант, заключающийся в определении диапазона изменения параметров конструкций в размерном виде с последующим их преобразованием в безразмерный вид.

Непрерывный тип нейросетей моделирования оболочек представляется наиболее функциональным, так как имеет значительно меньшие затраты на подготовку обучающего набора данных (за счет синтетического построения набора данных) и позволяет получить полную информацию о поведении конструкции под воздействием нагрузки в произвольной ее точке (за счет непрерывности). Однако в научной литературе имеется мало сведений о проектировании и обучении подобного типа нейросетей при моделировании оболочек.

В области построения непрерывных нейросетевых моделей, обученных на синтетических данных, был получен ряд оригинальных результатов, в частности реализована нейросеть моделирования двояковыпуклых [20] и цилиндрических [21] оболочек. Их использование позволило достичь сокращения длительности вычислений примерно в 1000 раз по сравнению с классическим ПО моделирования оболочек без существенной потери в точности моделирования. Для подготовки обучающего набора данных было разработано высокопроизводительное ПО расчета оболочек OptiShellX [22]. Для реализации нейросети использовался язык программирования Julia [23] и библиотека Flux.jl.

При использовании непрерывной нейросетевой модели возможны два подхода к формированию обучающего набора данных. Выбранный подход влияет на архитектуру нейросети и процесс обучения, поэтому можно считать, что эти два подхода образуют дополнительную классификацию среди непрерывных моделей. Первый вариант (далее он будет обозначаться как непосредственный тип нейросети) заключается в обучении нейросети на значениях различных компонент НДС в каждой точке конструкции. Нейросеть принимает в качестве входных данных геометрические и физические характеристики оболочки, прикладываемую нагрузку, а также координаты исследуемой точки на ее поверхности. Выходными данными нейросети служат значения компонент НДС в этой точке для заданной нагрузки.

Чтобы обучить непосредственную нейросеть, необходимо выполнить дискретизацию, т. е. задать некоторую сетку узлов на поверхности оболочки, а затем рассчитать для каждой конструкции и каждого значения компонент НДС в каж-

дом узле этой сетки. Использовать одну и ту же дискретизацию в таких задачах нецелесообразно, так как нейросеть «привыкает» к постоянным координатам и не может обеспечить удовлетворительную точность моделирования на произвольных. Следовательно, необходимо использовать случайным образом генерируемую сетку дискретизации и перестраивать ее через каждые несколько эпох обучения.

Преимущество такого подхода состоит в универсальности. Для обучения сети подходят данные, полученные в рамках физического эксперимента или использования любого ПО моделирования конструкций. Недостаток подхода заключается в том, что формирование обучающего набора данных представляет собой относительно сложную процедуру, а длительность обучения сети существенно возрастает из-за большого объема обрабатываемых данных.

Второй тип нейросети (далее он будет обозначаться как коэффициентный) предполагает обучение непосредственно на параметрах, описывающих решение задачи для конкретной конструкции и конкретного нагружения. Нейросеть принимает в качестве входных данных геометрические и физические характеристики оболочки, а также прикладываемую нагрузку. Координаты точки на поверхности конструкции в этом случае не требуются. Выходными данными нейросети служат неизвестные параметры, определяемые в процессе численного моделирования конструкции.

Рассмотрим применение метода Ритца в сочетании с этой архитектурой. При использовании модели Тимошенко–Рейснера получим 5 компонент НДС, которые используются для аппроксимации функционала полной потенциальной энергии деформации (ФППЭД). Если каждая аппроксимационная функция состоит из 16 слагаемых, при каждом из которых имеется неизвестный весовой коэффициент, то получим 80 аппроксимационных коэффициентов, описывающих поведение конструкции под воздействием нагрузки. Эти 80 коэффициентов описывают поведение конструкции в любой ее точке, из-за чего исчезает необходимость в дискретизации поверхности и обновлении случайного блока обучающих данных.

Однако этот подход может быть применим не во всех случаях. Если используется метод конечных элементов (МКЭ) и задано большое количество элементов, то конструкция может моделироваться тысячами отдельных элементов, каждый из которых описывается множеством параметров.

Дополнительно в этом случае для всех синтетических вычислительных экспериментов нужно сохранять одинаковое количество конечных элементов (для фиксации размерности вектора выходных данных нейросети).

Преимуществом такого типа нейросетей служит упрощение программной реализации и ускорение процесса обучения, недостатком – ограниченность его применимости в сочетании с некоторыми численными методами.

Непосредственный тип непрерывной нейросети был успешно использован в задаче моделирования цилиндрических оболочек [21]. В частности, он позволил добиться точности моделирования вертикального прогиба конструкции порядка 10 % толщины конструкции относительно тестового набора данных. В рамках данной статьи была проведена апробация нейросети коэффициентного типа. К сожалению, было обнаружено, что такая сеть не позволяет обеспечить высокой точности моделирования. Обученная нейронная сеть не могла точно смоделировать поведение оболочек, теряющих устойчивость при малых значениях нагрузки, что существенно ограничивало возможности ее применения.

Вероятным объяснением того, что теоретически более простая в обучении коэффициентная нейросеть не смогла продемонстрировать высокой точности моделирования, может стать то, что она решает значительно более сложную задачу. Ввиду повышения опосредованности задачи возрастает сложность обучения, в связи с чем данный подход требует более детального изучения для определения задач, в которых он может быть эффективно использован.

Рассмотренные способы классификации нейросетевых моделей представлены на рис. 1.

Классическое и нейросетевое моделирование. Далее будет подробно рассмотрен процесс обучения нейросети непрерывного типа с использованием синтетических данных. Данные для обучения нейросети состоят из результатов расчета цилиндрических оболочек, полученных с использованием авторского ПО OptiShellX. Оно выполняет моделирование в соответствии с геометрически-нелинейной и физически-линейной математической моделью Тимошенко–Рейснера посредством решения соответствующей вариационной задачи по методу Ритца [1]. Нагрузка, прикладываемая к моделируемым конструкциям, – равномерно распределенная, направленная нор-

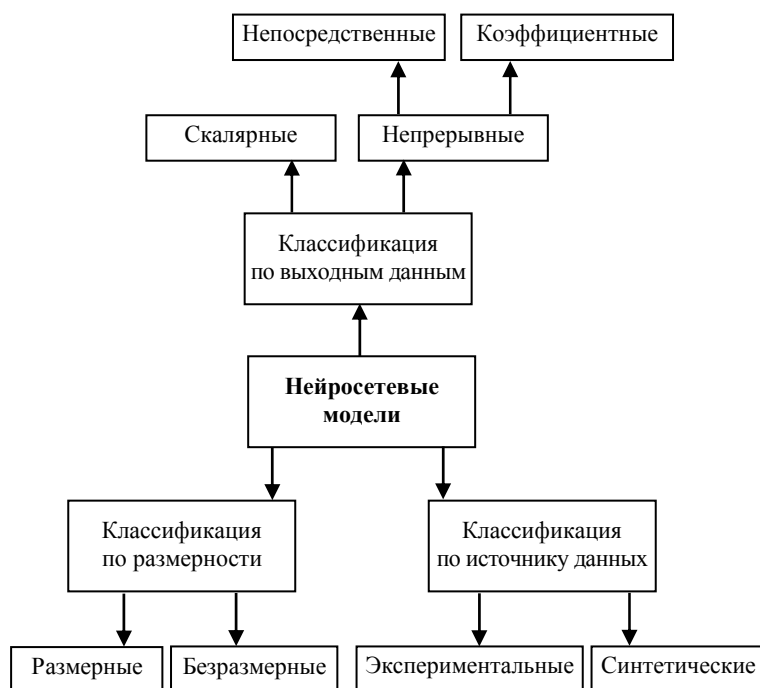


Рис. 1. Классификация нейросетевых моделей деформирования оболочек
 Fig. 1. Classification of neural network models of shell deformation

мально к срединной поверхности. Материал конструкции – изотропный. Конструкция закреплена по периметру шарнирно-неподвижно.

Отметим, что вычислительный процесс с использованием OptiShellX предполагает переход к безразмерной математической модели [24], двухмерное численное интегрирование в рамках метода Рунге, а также многомерную минимизацию по методу продолжения по наилучшему параметру [25], т. е. представляет собой сложный с вычислительной точки зрения ресурсоемкий процесс. В то же время, нейросетевое моделирование требует значительно меньших вычислений, имеет константную асимптотическую сложность и обладает допустимой погрешностью в сравнении с классическим моделированием.

Определение конфигураций конструкций.

Для удобства формирования обучающего набора данных опишем конфигурации оболочек в размерном виде, а затем выполним их конвертацию в безразмерную форму. Цилиндрическая оболочка определяется следующими параметрами: линейным размером a (метры), углом раскрытия b (радианы), радиусом кривизны R (метры) и толщиной h (метры). Ввиду тонкостенности оболочек на толщину конструкции накладывается следующее ограничение [1]:

$$a, bR, R > 20h,$$

т. е. два линейных размера и радиус кривизны оболочки должны быть в 20 раз больше толщины. При этом желательно, чтобы конструкции из используе-

мого набора конфигураций имели различные шаблоны поведения под воздействием нагрузки. Это позволит лучше оценить эффективность предлагаемой нейросети с точки зрения обобщения поведения различных конфигураций оболочек. Дополнительно для обучения нейронной сети необходимо иметь набор данных, достаточно большой для того, чтобы она смогла обобщить результаты моделирования различных конструкций. В то же время, слишком большое количество различных конфигураций приведет к существенному увеличению длительности обучения и, возможно, переобучению.

Всем этим условиям соответствует следующий набор конфигураций:

- 1) $a \in 10 \dots 40$ м с шагом 5 м (итого 7 значений);
- 2) $b \in \pi/2 \dots \pi$ рад с шагом 1 рад или 15° (итого 7 значений);
- 3) $h \in 0.01 \dots 0.05$ м с шагом 0.01 м (итого 5 значений);
- 4) $R \in 5 \dots 25$ м с шагом 5 м (итого 6 значений).

Количество уникальных геометрических конфигураций составляет 1470 конфигураций.

В безразмерном представлении геометрия цилиндрической оболочки (в соответствии с [24]) описывается следующими четырьмя безразмерными параметрами:

$$\lambda = \frac{a}{bR}, k_\eta = \frac{h}{R}, \bar{A} = \frac{a}{h}, \bar{B} = \frac{bR}{h}.$$

Рассмотрим описание материала конструкции. В качестве возможных материалов оболочек были выбраны материалы:

– сталь ($E = 2.1e^5$ МПа, $G = 8.07e^4$ МПа, $\mu = 0.30$);

– титан ($E = 1.1e^5$ МПа, $G = 4.38e^4$ МПа, $\mu = 0.32$);

– алюминий ($E = 0.71e^5$ МПа, $G = 2.62e^4$ МПа, $\mu = 0.35$),

где E – модуль упругости, G – модуль сдвига, μ – коэффициент Пуассона. Моделируемый материал изотропный, поэтому параметры связаны друг с другом соотношением $G = \frac{E}{2(1+\mu)}$, ввиду чего для

описания поведения конструкции достаточно оставить лишь два параметра, например E , μ .

Общее количество конфигураций оболочек составляет 4410 конфигураций.

Входные и выходные данные нейросети.

Для того чтобы выполнить расчет конструкции под воздействием нагрузки в некоторой ее точке, необходимо определить геометрические и физические параметры конструкции, а также 3 дополнительных параметра: координаты x , y рассматриваемой точки срединной поверхности оболочки и прикладываемую равномерно-распределенную нагрузку q . Точки срединной поверхности целесообразно представить с использованием безразмерных единиц (т. е. $0 \leq x, y \leq 1$) с тем, чтобы для всех рассматриваемых конфигураций одни и те же относительные точки поверхности имели одинаковые координаты.

Выходными данными нейросети являются компоненты НДС по модели Тимошенко–Рейснера, т. е. 5 значений: U , V , W (функции, определяющие поперечные, продольные и вертикальные перемещения соответственно) и Ψ_x , Ψ_y (функции, связанные с углами поворота нормали в плоскостях xOz и yOz соответственно) в точке (x, y) срединной поверхности оболочки.

Таким образом, минимальный набор входных данных нейронной сети включает в себя нагрузку, 2 координаты x , y , 4 геометрических параметра λ , k_η , \bar{A} , \bar{B} и 2 параметра материала E , μ . Выходными данными служат 5 вещественных чисел U , V , W , Ψ_x , Ψ_y , описывающих НДС в конкретной точке конструкции.

Моделирование конструкций. Был проведен вычислительный эксперимент, в рамках которого моделировались описанные ранее конфигурации

оболочек. Для расчета использовалось авторское ПО OptiShellX. Оно позволяет выполнить моделирование численным решением вариационной задачи для функционала полной потенциальной энергии деформации (ФППЭД) с использованием квази-ньютоновского метода LBFGS (Limited-memory Broyden–Fletcher–Goldfarb–Shanno algorithm, ограниченный по памяти алгоритм Бройдена–Флетчера–Гольдфарба–Шанно) либо с использованием метода продолжения по наилучшему параметру (МППНП) [25]. Как будет показано далее, применение МППНП для данной задачи имеет ряд трудностей, связанных с непрерывностью решения в области потери устойчивости. Однако МППНП в сравнении с LBFGS предполагает решение последовательности систем линейных алгебраических уравнений вместо систем нелинейных алгебраических уравнений (в случае использования LBFGS), что позволяет сократить длительность минимизации ФППЭД примерно в 20 раз (с 49.7 до 2.6 с). В связи с этим был разработан ряд вспомогательных алгоритмов обработки результатов моделирования по МППНП, позволяющих использовать полученные результаты вычислений для обучения нейросети. Эти алгоритмы могут быть применены и к любому другому методу, где результаты моделирования в области потери устойчивости непрерывны.

Расчет выполнялся со следующими параметрами:

– количество аппроксимационных слагаемых по методу Рунге – 16;

– максимально возможный прогиб в устойчивом состоянии конструкции, по превышении которого вычисления завершаются – $20h$;

– максимальная допустимая нагрузка – 5.0 МПа.

Отличительной чертой МППНП в сравнении с квази-ньютоновскими методами служит то, что получаемые результаты вычислений могут быть неоднозначны с точки зрения прикладываемой к конструкции нагрузки. Другими словами, одной и той же нагрузке в области потери устойчивости может соответствовать несколько точек на диаграмме «нагрузка–прогиб». Это существенно усложняет процедуру обучения и архитектуру нейросети, поэтому перед использованием результатов вычислений в качестве обучающего набора данных необходимо провести их предварительную обработку, линеаризацию области потери устойчивости.

Для наглядности рассмотрим некоторую оболочку из описанного ранее набора. Диаграмма «нагрузка (q) – максимальный прогиб» для нее

приведена на рис. 2, а. Как можно видеть, на участке от 0.6 до 0.7 МПа одним и тем же значениям прикладываемой нагрузки соответствуют несколько возможных состояний.





Рис. 2. Диаграмма «нагрузка – максимальный прогиб» до (а) и после (б) линейризации и линейной интерполяции

Fig. 2. «Load – maximal vertical displacement» diagram for a shell before (a) and after (b) linearization and linear interpolation

Для устранения неоднозначности этой диаграммы применим следующий алгоритм. Последовательно рассматривается каждый вектор решения метода МППНП. Если текущий вектор-решение имеет значение нагрузки большее, чем ранее рассмотренный вектор решения, то этот вектор включается в новое, «отфильтрованное» решение. Если значение нагрузки оказывается меньше предыдущего, то это решение не включается в новое решение.

Дополнительно расчет по МППНП включает в себя сотни и тысячи векторов-решений с неравномерным шагом по нагрузке. Это связано с тем, что в МППНП нагрузка представляет один из неизвестных параметров, определяемых на каждой итерации метода. В то же время, использование столь объемного набора данных крайне негативно сказывается на скорости обучения нейросети. Наиболее тривиальный подход к решению этой проблемы – извлечение из исходного набора векторов-решений каждого i -го элемента таким образом,

чтобы общее количество точек после извлечений имело приемлемое значение. Однако он недостаточно эффективен из-за использования переменного шага в МППНП. На одном интервале по нагрузке может быть лишь 2–3 точки, в то время как на следующем интервале такого же размера их может быть 10–20. Более эффективным решением оказалось применение линейной интерполяции по нагрузке к линейризованным данным (рис. 2, б).

Последняя особенность, которую необходимо учесть, – это реализованное в ПО OptiShellX условие завершения вычислений. Программа завершает работу по превышении требуемой нагрузки или по достижении некоторого значения прогиба, однако этот прогиб должен быть зарегистрирован вне области потери устойчивости. Новое устойчивое состояние может иметь значительно больший прогиб, чем предыдущее (рис. 3, а), поэтому после удаления из диаграммы области потери устойчивости новое состояние будет описано лишь одним вектором-решением (рис. 3, б). Очевидно, что наличие подобных векторов при обучении нейросети приводит к ухудшению процесса обучения.


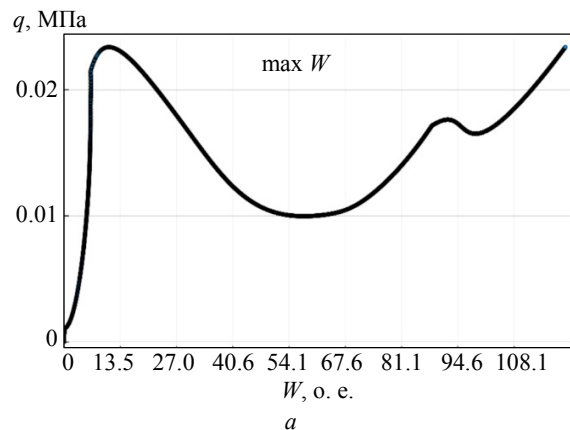


Рис. 3. Диаграмма «нагрузка – максимальный прогиб» оболочки, до (а) и после (б) применения линейризации
Fig. 3. «Load – maximal vertical displacement» diagram for a shell, before (a) and after (b) applying linearization

Для оценки распространенности подобной ситуации в обучающем наборе данных была построена точечная диаграмма (рис. 4, *а*), где по горизонтальной оси для каждой конструкции отложен максимальный вертикальный прогиб (в безразмерных единицах), а по вертикальной оси – соответствующая нагрузка. На приведенной диаграмме можно выделить структурные элементы. Выровненные по верхней границе $q = 5.0$ МПа результаты расчетов – это те конфигурации, для которых сработало завершение вычислений по достижении максимальной нагрузки. Группа решений около прямой $W = 20.0$ соответствует тем конструкциям, для которых сработало завершение вычислений по достижении максимального прогиба. Конфигурации за пределом границы в $20h$ представляют собой те расчеты, для которых критическое состояние представлено в виде одного вектора-решения, отделенного разрывом от остальной части диаграммы.

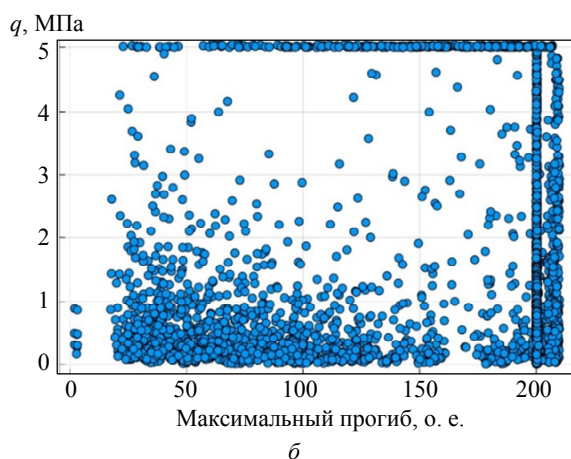
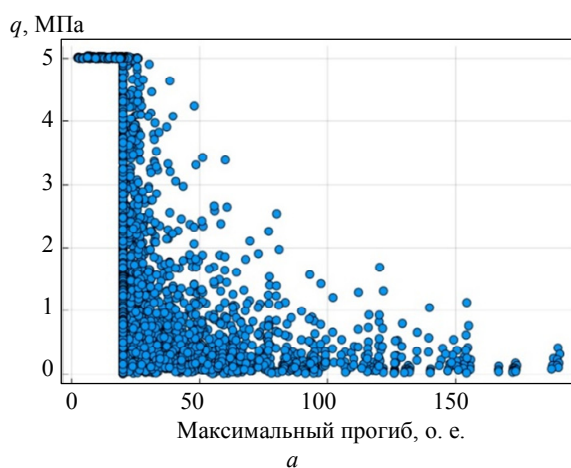


Рис. 4. Точечная диаграмма распределения решений по максимальному прогибу и нагрузке до (*а*) и после обработки (*б*)

Fig. 4. Scatter diagram for distribution the solutions for maximum deflection and load before (*a*) and after (*b*) processing

Для дополнительной оценки максимального прогиба в обучающем наборе данных были вычислены базовые статистические характеристики:

- среднее: 30.243;
- минимум: 2.2834;
- 1-й квартиль: 20.016;
- медиана: 20.040;
- 3-й квартиль: 27.930;
- максимум: 190.719.

Как можно видеть из полученных данных, примерно 75 % результатов моделирования содержат подобные «закритические» решения. Для устранения этой проблемы, из каждого подобного расчета конструкции были исключены те векторы-решения, которые соответствуют прогибу, превышающему $W = 21.0h$. Дополнительная единица толщины включена с учетом того, что последний вектор-решение всегда описывает прогиб немного больше требуемого (вычисления завершаются по превышении прогиба в $20.0h$, но последний вектор-решение, описывающий этот прогиб, также включается в итоговое решение). Итоговая диаграмма распределения решений по максимальному прогибу и нагрузке приведена на рис. 4, *б*.

Формирование обучающего набора данных. После того как было выполнено моделирование оболочек и проведена непосредственная обработка результатов моделирования, необходимо построить наборы входных и выходных данных, используемых для обучения и тестирования нейронной сети.

Полученные ранее результаты расчетов для конфигураций оболочек были случайным образом разбиты на 80 % обучающих, 10 % валидационных и 10 % тестовых данных. Обучающие данные используются в процессе обучения нейросети, по ним обновляются веса нейросети. Валидационные данные используются для оценки точности моделирования в процессе обучения. Тестовые данные используются для сравнения разных конфигураций нейросетей между собой.

Затем была выполнена дискретизация расчетов на двумерной сетке. С учетом безразмерности рассматриваемых конструкций, введем на квадрате размером 1.0×1.0 равномерную сетку из $N \times N$ узлов. В данной статье $N = 9$, благодаря чему узлы сетки попадают на координаты $1/8$, $1/4$ и $1/2$, которые чаще всего используются для построения диаграмм «нагрузка–прогиб».

Для каждой конфигурации оболочки и для каждого конкретного значения нагрузки необходимо выполнить расчет компонент НДС в каждой

точке этой сетки. Однако если использовать только равномерную сетку, нейросеть в процессе обучения будет обладать высокой точностью моделирования только в этих узлах. Для решения проблемы был использован дополнительный набор из $N \times N$ случайных точек, перестраиваемый в процессе обучения сети. Также, для корректного обучения нейросети моделированию на границе оболочки, в набор точек дискретизации были включены 4 группы по N точек: $(x; 0.0)$, $(x; 1.0)$, $(0.0; y)$, $(1.0; y)$, где x, y – случайные равномерно распределенные величины из интервала $[0; 1]$. Обновление случайной части обучающего набора данных выполнялось каждые 10 эпох обучения.

В общей сложности на один результат расчета при фиксированном значении нагрузки приходится $2N^2 + 4N = 198$ точек. В каждой из этих точек необходимо вычислить 5 функций: U, V, W, Ψ_x, Ψ_y . Подобные вычисления необходимо выполнить для всех 4410 конструкций при каждом из 50 возможных значений по нагрузке. Следовательно, общее количество векторов входных и выходных данных составляет 43 659 000. Даже с учетом того, что часть из них (та, которая соответствует равномерной сетке, а также та часть, которая соответствует тестовому и валидационному наборам) может быть построена однократно, случайно-генерируемый набор точек требует регулярно вычисления 25 798 500 значений компонент НДС. В связи с чем для расчета этих компонент при формировании обучающего набора данных

рекомендуется использовать скомпилированные функции, тем самым минимизировав длительность вычислений.

Архитектура нейронной сети. Наиболее эффективной для рассматриваемой задачи показала себя следующая нейросетевая архитектура (рис. 5, а). Входной слой сети состоит из 9 параметров. Из них 4 параметра определяют геометрию, 2 – свойства материала, 2 – координаты рассматриваемой точки конструкции, 1 – значение прикладываемой нагрузки. После входного слоя располагается слой пакетной нормализации. Сеть продолжается 5 полносвязными слоями каждый по $18 \times 9 = 162$ нейрона, функция активации – ReLU.

Дальнейшее моделирование осуществляется через пять независимых подсетей с общей архитектурой, в которые подаются выходные данные последнего описанного слоя, а также входные данные сети (рис 5, б). Входной слой подсетей включает 171 нейрон (9 параметров от проброски входного слоя, 162 – от предыдущего слоя сети). Далее идут пакетная нормализация и 4 полносвязных слоя по 171 нейрону с активацией ReLU. Каждая из 5 подсетей имеет 1 выходной нейрон с единичной активацией, позволяющей им возвращать как положительные, так и отрицательные значения. Выходные нейроны подсетей объединяются в выходной слой сети.

По результатам проводимых исследований описываемая архитектура с подсетями показала себя наиболее эффективной. Несколько полно-

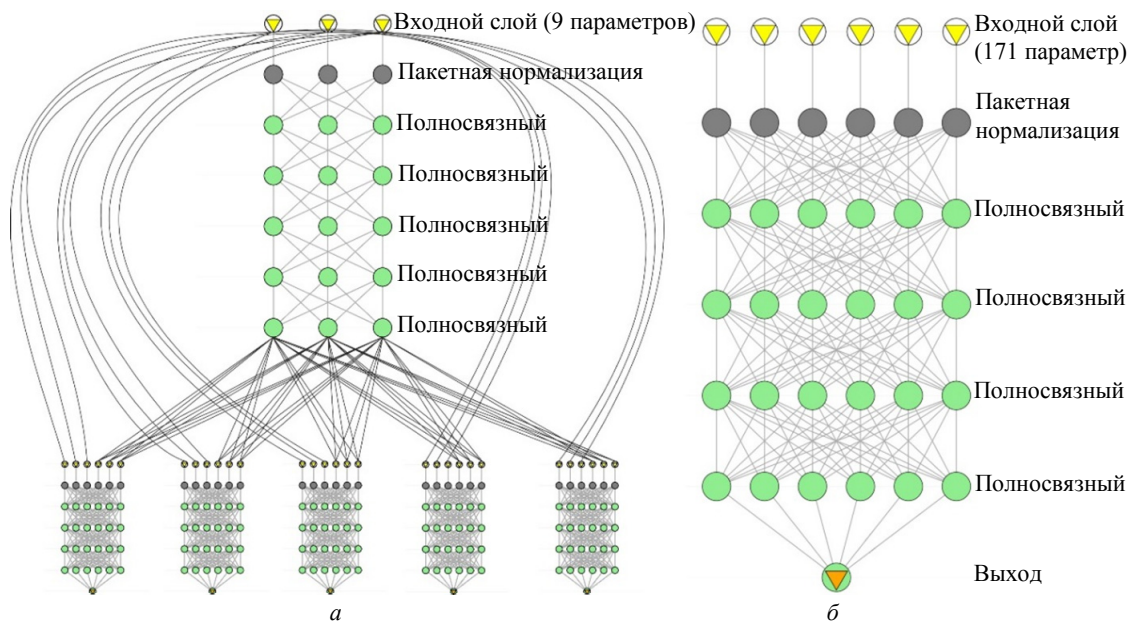


Рис. 5. Схематическое представление архитектуры нейросети: в целом (а) и для подсети (б)
Fig. 5. Schematic representation of the neural network architecture: in total (a) and for a subnet (b)

связных слоев в начале сети выполняют промежуточные вычисления, общие для каждой компоненты НДС, а отдельные подсети используют эти данные и данные со входного слоя нейросети для расчета конкретных компонент НДС. В рамках данного исследования анализировались и более простые конфигурации, например многослойные перцептроны без подсетей для описания отдельных компонент НДС. Однако было обнаружено, что при моделировании оболочек такие сети требуют большего количества эпох обучения для обеспечения аналогичной точности моделирования при сопоставимом количестве обучаемых параметров.

Обсуждение результатов. Для обучения нейронной сети был использован оптимизатор ADAM (Adaptive Moment Estimation, метод адаптивной оценки моментов) с начальной скоростью обучения 0.001. В качестве функции потерь использовалась функция MAE (англ. Mean Absolute Error, средняя абсолютная ошибка). Обучение выполнялось в течение 251 эпохи, на последних 50 итерациях скорость обучения была снижена с 0.001 до 0.0001. По результатам обучения были получены следующие метрики:

– значение функции потерь на тестовом наборе данных: 3.92. Снижение ошибки по сравнению с обучающим набором данных обусловлено ис-

пользованием BN-слоев (Batch Normalization, слой пакетной нормализации);

– значение функции потерь на тестовом наборе для отдельных компонент: U : 1.95; V : 14.59; W : 0.13; Ψ_x : 0.81; Ψ_y : 2.11.

Интерпретация MAE для компонент (за исключением вертикального прогиба W) затруднительна, так как при переходе от безразмерных величин к размерным необходимо учитывать параметры Ляме и геометрические параметры оболочки. MAE для W составляет 0.13 толщины оболочки, что представляется достаточно высоким показателем точности моделирования. Для оценки качества обучения нейросети по остальным компонентам НДС необходимо учитывать статистические характеристики отдельных компонент НДС в обучающих данных (табл. 1).

Как можно видеть из приведенной таблицы, компоненты НДС (за исключением W) имеют достаточно широкие диапазоны, но при этом большинство значений сконцентрировано около нуля. В общей сложности погрешность нейросетевого моделирования можно считать низкой.

Помимо описанной конфигурации сети были апробированы и другие, отличающиеся от нее отсутствием пакетной нормализации, количеством слоев и нейронов в слоях. Сведения о них приведены в табл. 2, где используются следующие

Табл. 1. Статистика по выходным данным в обучающем наборе
Tab. 1. Statistics for output data in the training set

Характеристика	Параметр				
	U	V	W	Ψ_x	Ψ_y
Среднее	0.0	0.0	1.1	0.0	0.0
Стандартное отклонение	81.6	679.8	3.3	14.7	52.6
Минимум	-3720.7	-16636.5	-23.0	-195.4	-376.1
1-й квартиль	0.0	-0.2	0.0	-0.8	-4.8
Медиана	0.0	0.0	0.0	0.0	0.0
3-й квартиль	0.0	0.2	1.3	0.8	4.8
Максимум	3 720.7	16 636.5	20.9	195.4	376.1

Табл. 2. Результаты тестирования альтернативных конфигураций нейросетей
Tab. 2. Results of validation of alternative neural network configurations

Наименование сети	Э	РС	ЧГ	BN	CO	НО	СП	НП	П	U	V	W	Ψ_x	Ψ_y
А	250	5 × 5	25	Нет	2	18	1	27	5189	20.67	176.34	0.84	4.70	17.93
Б	250	5 × 5	25	Нет	5	18	4	27	20 930	13.89	143.70	0.55	3.67	11.88
В	250	11 × 11	25	Нет	5	18	4	27	20 930	11.31	82.64	0.40	3.37	8.29
Г	75	11 × 11	25	Нет	5	144	4	153	695 660	3.37	22.01	0.23	1.28	3.08
Д	251	9 × 9	10	Да	5	162	4	171	698 072	1.95	14.59	0.13	0.81	2.11
Е	280	9 × 9	10	Да	5	162	4	256	1 317 297	2.13	15.42	0.14	0.79	2.46

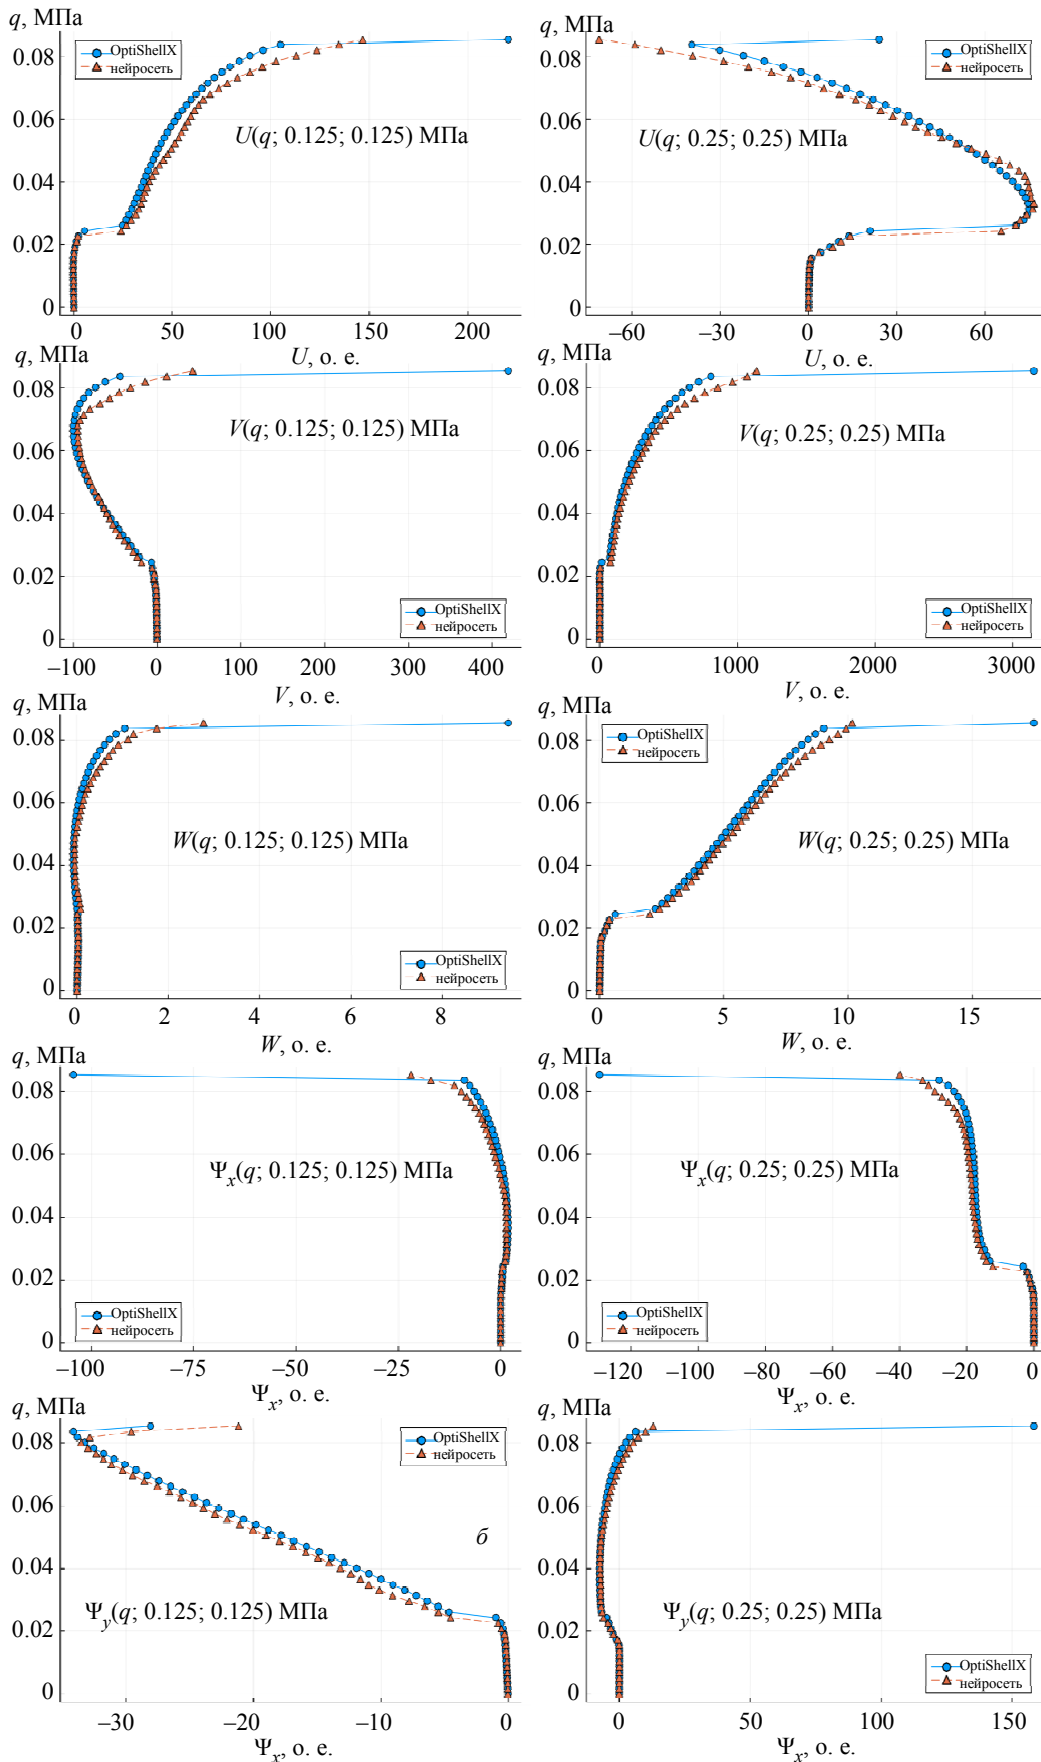


Рис. 6. Набор диаграмм НДС в разных точках срединной поверхности оболочки
Fig. 6. A set of SSS diagrams in different points of the middle surface of the shell

обозначения: \mathcal{E} – количество эпох обучения; PC – размер случайного перестраиваемого обучающего набора данных, $ЧГ$ – частота генерации обновленного случайного набора данных, BN – наличие или отсутствие BN -слоев; CO – количество слоев в «обобщающем» блоке, $НО$ – количество нейронов в слоях «обобщающего блока», $СП$ – количество промежуточных слоев в одной подсети, $НП$ – количество нейронов в промежуточных слоях подсети, $П$ – количество параметров обучения сети, U, V, W, Ψ_x, Ψ_y – значения MAE для соответствующих компонент НДС оболочки.

Как можно видеть из табл. 2, описанная архитектура (в таблице она обозначена как сеть «Д») демонстрирует наиболее высокие показатели точности моделирования. Для нейронной сети «Г» обучение было приостановлено, не доходя до 250 итераций, ввиду обнаружения признаков переобучения. После дополнения данной архитектуры пакетной нормализацией проблема переобучения была устранена. Увеличение количества нейронов в процессе обучения (сеть «Е») не позволило повысить точность моделирования за аналогичное количество итераций.

Для того чтобы более наглядно продемонстрировать точность нейросетевой модели и оценить ее производительность, рассмотрим цилиндрическую оболочку, описанную в [26]. Она имеет следующие параметры: $a = 20$ м; $b = 1.57$ рад; $R = 5.4$ м; $h = 0.01$ м; $E = 2.1e^5$ МПа; $G = 8.08e^4$ МПа; $\mu = 0.3$. Прикладываемая к конструкции нагрузка – равномерно распределенная, нормальная к срединной поверхности в интервале от 0.00 до 0.86 МПа, закрепление – шарнирно-неподвижное. Эта конфигурация оболочки полностью соответствует диапазону входных данных обученной нейросети. На рис. 6 приведены диаграммы для 5 компонент НДС в четверти и одной восьмой срединной поверхности оболочки, т. е. в точках $(1/4, 1/4)$, $(1/8, 1/8)$.

В [26] для данной конструкции была определена критическая нагрузка, примерно равная 0.08 МПа. Этот результат хорошо согласуется с результатами, полученными с использованием OptiShellX, а также с результатами нейросетевого моделирования. В целом, результаты нейросетевого моделирования практически полностью совпадают с результатами, полученными через OptiShellX.

Длительность расчета данной оболочки с применением OptiShellX составила примерно 8.2 с при использовании GPU и 39.9 с – без этого. Полный нейросетевой расчет этих диаграмм потребовал лишь 8 мс, т. е. по 4 мс на каждую точку $(1/4, 1/4)$,

$(1/8, 1/8)$, что примерно в 1025 раз быстрее GPU-реализации и в 4988 раз быстрее CPU-реализации.

Для дополнительной оценки точности нейросети было выполнено моделирование 48 оболочечных конструкций с разными материалами и геометрическими характеристиками, не совпадающими со значениями из обучающего набора данных:

- $a \in (17.5, 22.5, 27.5$ м);
- $b \in (112.0, 127.5, 142.5^\circ)$;
- $h \in (0.025, 0.035, 0.045$ м);
- $R \in (12.5, 17.5, 22.5$ м);
- материал: сталь, титан, алюминий.

Ни одно из приведенных ранее значений геометрических параметров не использовалось при генерации обучающего набора данных, что позволяет дополнительно проверить нейросеть на переобучение. Для рассматриваемого набора данных значение функции потерь составило 3.948, а значения функции потерь для отдельных компонент – $U: 2.16$; $V: 14.46$; $W: 0.16$; $\Psi_x: 0.79$; $\Psi_y: 2.17$, т. е. наблюдается точность моделирования, близкая к точности нейросети на тестовом наборе данных.

Выводы и заключение. Таким образом, поставленная в рамках данной статьи цель была выполнена. На базе литературного обзора и серии вычислительных экспериментов предложена классификация различных подходов к формированию нейросетевых моделей деформирования оболочек, а также описаны преимущества и недостатки различных типов нейросетевых моделей. Предложена процедура обучения нейронной сети моделирования НДС оболочечной конструкции и, в соответствии с этой процедурой, выполнено обучение подобной нейросети. Ряд вычислительных экспериментов с использованием нейросетевой модели показал сокращение длительности вычислений с десятков секунд до нескольких миллисекунд с несущественной для решения практических задач потерей в точности моделирования.

Наиболее перспективными по результатам данного исследования представляются непрерывные непосредственные модели, обученные на синтетических безразмерных данных. Для нейросетей такого типа не требуется проведение физических экспериментов, при этом они обеспечивают наиболее информативное представление сведений о поведении конструкций под воздействием внешних сил, обладают высокой точностью и производительностью моделирования. Также перспективным представляется применение коэффицентных нейросетей, однако их использование требует дальнейшего изучения.

Список литературы

1. Karpov V. V. Models of the shells having ribs, reinforcement plates and cut-outs // Intern. J. of Solids and Structures. 2018. Vol. 146. P. 117–135. doi:10.1016/j.ijsolstr.2018.03.024.
2. Experimental and numerical analyses on buckling and strength failure of composite cylindrical shells under hydrostatic pressure / X. Zhang, Z. Li, P. Wang, G. Pan // Ocean Engin. 2022. Vol. 249. P. 110871. doi: 10.1016/j.oceaneng.2022.110871.
3. Kishore S., Naik Parrikar P., Shukla A. Response of an underwater cylindrical composite shell to a proximal implosion // J. of the Mechan. and Phys. of Solids. 2021. Vol. 152. P. 104414. doi: 10.1016/j.jmps.2021.104414.
4. A novel analytical study on the buckling of cylindrical shells subjected to arbitrarily distributed external pressure / L. Yang, Y. Luo, T. Qiu, H. Zheng, P. Zeng // European J. of Mechan. – A/Solids. 2022. Vol. 91. P. 104406. doi:10.1016/j.euromechsol.2021.104406.
5. Analytical, numerical and experimental study of the plastic buckling behavior of thick cylindrical tubes under axial compression / J. Legendre, P. Le Grogne, C. Doudard, S. Moyne // Intern. J. of Mechanical Sci. 2019. Vol. 156. P. 494–505. doi:10.1016/j.ijmecsci.2019.03.002.
6. Петров Д. С., Семенов А. А. Анализ устойчивости ортотропной цилиндрической оболочечной конструкции в программном комплексе ANSYS Mechanical APDL // Науч.-техн. вестн. информационных технологий, механики и оптики. 2023. Т. 23, № 3. С. 618–627. doi: 10.17586/2226-1494-2023-23-3-618-627.
7. Mandal A., Ray C., Haldar S. Experimental and numerical studies on vibration characteristics of laminated composite skewed shells with cutout // Composites Part B: Engin. 2019. Vol. 161. P. 228–240. doi: 10.1016/j.compositesb.2018.10.075.
8. Daniel J. J. Scientific investigation on the stress minimization of the RC thin roof structures using Finite element method of analysis // Materials Today: Proc. 2021. Vol. 45. P. 6270–6276. doi: 10.1016/j.matpr.2020.10.703.
9. Alanani M., Elshaer A. ANN-based optimization framework for the design of wind load resisting system of tall buildings // Engin. Structures. 2023. Vol. 285. P. 116032. doi: 10.1016/j.engstruct.2023.116032.
10. Design and evaluation of a prediction-based dynamic edge computing system / E. Liu, X. Deng, Z. Cao, H. Zhang // 2018 IEEE Global Communications Conf. (GLOBECOM). Abu Dhabi, United Arab Emirates: IEEE, 2018. P. 1–6. doi: 10.1109/GLOCOM.2018.8647199.
11. Raissi M., Perdikaris P., Karniadakis G. E. Physics-Informed Neural Networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations // J. of Computational Phys. 2019. Vol. 378. P. 686–707. doi: 10.1016/j.jcp.2018.10.045.
12. Scientific machine learning through Physics-Informed Neural Networks: where we are and what's next / S. Cuomo, V. S. Di Cola, F. Giampaolo, G. Rozza, M. Raissi, F. Piccialli // J. of Scientific Comp. 2022. Vol. 92, no. 3. Art. 88. P. 1–62. doi: 10.1007/s10915-022-01939-z.
13. Bastek J.-H., Kochmann D. M. Physics-Informed Neural Networks for shell structures // European J. of Mechan. – A/Solids. 2023. Vol. 97. P. 104849. doi: 10.1016/j.euromechsol.2022.104849.
14. E W., Yu B. The Deep Ritz Method: A deep learning-based numerical algorithm for solving variational problems // Communications in Math. and Statistics. 2018. Vol. 6, no 1. P. 1–12. doi: 10.1007/s40304-018-0127-z.
15. Decision tree-based machine learning to optimize the laminate stacking of composite cylinders for maximum buckling load and minimum imperfection sensitivity / H. N. R. Wagner, H. Köke, S. Dähne, S. Niemann, C. Hühne, R. Khakimova // Composite Structures. 2019. Vol. 220. P. 45–63. doi: 10.1016/j.compstruct.2019.02.103.
16. A machine learning method for buckling design of internally pressurized torispherical heads considering geometric imperfection / F. Liu, J. Yang, S. Weng, F.-Z. Xuan, J.-G. Gong // Thin-Walled Structures. 2023. Vol. 189. P. 110908. doi:10.1016/j.tws.2023.110908.
17. Application of artificial neural network to predict buckling load of thin cylindrical shells under axial compression / Z. ul R. Tahir, P. Manda, M. T. Adi, F. Naz // Engin. Structures. 2021. Vol. 248. P. 113221. doi: 10.1016/j.engstruct.2021.113221.
18. Prediction of compression buckling load and buckling mode of hat-stiffened panels using artificial neural network / Z. Sun, Z. Lei, R. Bai, H. Jiang, J. Zou, Y. Ma, C. Yan // Engin. Structures. 2021. Vol. 242. P. 112275. doi: 10.1016/j.engstruct.2021.112275.
19. Ribeiro J., Tavares S., Parente M. Stress-strain evaluation of structural parts using artificial neural networks // Proc. of the Institution of Mechanical Engineers. Part L: J. of Materials Design and Appl. 2021. P. 1271–1286. doi: 10.1177/1464420721992445.
20. Zgoda Iu. N. High performance modeling of the stress-strain state of thin-walled shell structures with the use of deep learning // Scientific and Techn. J. of Inform. Technol., Mechan. and Optics. 2023. Vol. 23, no. 2. P. 430–435. doi: 10.17586/2226-1494-2023-23-2-430-435.
21. Згода Ю. Н. Возможности глубокого обучения применительно к задаче компьютерного моделирования тонкостенных оболочечных конструкций // Сб. тр. IV Междунар. конф. по нейронным сетям и нейротехнологиям (NeuroNt'2023). СПб.: СПбГЭТУ, 2023. С. 68–71.
22. Свид-во о рег. пр-мы для ЭВМ № 2023612571 (RU). OptiShellX – программа для высокопроизводительного расчета тонкостенных оболочечных конструкций / Ю. Н. Згода. Заяв. 27.01.23; опубл. 06.02.2023.
23. Julia: A Fresh approach to numerical computing / J. Bezanson, A. Edelman, S. Karpinski, V. B. Shah // SIAM Rev. 2017. Vol. 59, no. 1. P. 65–98. doi: 10.1137/141000671.
24. Карпов В. В., Семенов А. А. Безразмерные параметры в теории подкрепленных оболочек // Вестн. ПНИПУ. Механика. 2015. № 3. С. 74–94. doi: 10.15593/perm.mech/2015.3.07.

25. Семенов А. А., Леонов С. С. Метод непрерывного продолжения решения по наилучшему параметру при расчете оболочечных конструкций // Учен. зап. Казанского ун-та. Сер.: Физико-математические науки. 2019. Т. 161, № 2. С. 230–249. doi: 10.26907/2541-7746.2019.2.230-249.

26. Карпов В. В. Анализ алгоритмов исследования устойчивости тонкостенных оболочек // Изв. Саратовского ун-та. Новая серия. Сер.: Математика. Механика. Информатика. 2012. Т. 12, № 1. С. 63–69. doi: 10.18500/1816-9791-2012-12-1-63-69.

Информация об авторе

Згода Юрий Николаевич – специалист 2-й категории образовательного центра цифровых компетенций. Санкт-Петербургский государственный архитектурно-строительный университет, 2-я Красноармейская ул., д. 4, Санкт-Петербург, 190005, Россия.

E-mail: yurii.zgoda@mail.ru

<https://orcid.org/0000-0001-6714-500X>

References

1. Karpov V. V. Models of the shells having ribs, reinforcement plates and cut-outs // Intern. J. of Solids and Structures. 2018. Vol. 146. P. 117–135. doi:10.1016/j.ijsolstr.2018.03.024.

2. Experimental and numerical analyses on buckling and strength failure of composite cylindrical shells under hydrostatic pressure / X. Zhang, Z. Li, P. Wang, G. Pan // Ocean Engin. 2022. Vol. 249. P. 110871. doi: 10.1016/j.oceaneng.2022.110871.

3. Kishore S., Naik Parrikar P., Shukla A. Response of an underwater cylindrical composite shell to a proximal implosion // J. of the Mechan. and Phys. of Solids. 2021. Vol. 152. P. 104414. doi: 10.1016/j.jmps.2021.104414.

4. A novel analytical study on the buckling of cylindrical shells subjected to arbitrarily distributed external pressure / L. Yang, Y. Luo, T. Qiu, H. Zheng, P. Zeng // European J. of Mechan. – A/Solids. 2022. Vol. 91. P. 104406. doi:10.1016/j.euromechsol.2021.104406.

5. Analytical, numerical and experimental study of the plastic buckling behavior of thick cylindrical tubes under axial compression / J. Legendre, P. Le Grogneq, C. Doudard, S. Moyne // Intern. J. of Mechanical Sci. 2019. Vol. 156. P. 494–505. doi:10.1016/j.ijmecsci.2019.03.002.

6. Petrov D. S., Semenov A. A. Analiz ustojchivosti ortotropnoj cilindricheskoj obolocheknoj konstrukcii v programnom komplekse ANSYS Mechanical APDL // Nauch.-tehn. vestn. informacionnyh tehnologij, mehaniki i optiki. 2023. Т. 23, № 3. С. 618–627. doi: 10.17586/2226-1494-2023-23-3-618-627. (In Russ.).

7. Mandal A., Ray C., Haldar S. Experimental and numerical studies on vibration characteristics of laminated composite skewed shells with cutout // Composites Part B: Engin. 2019. Vol. 161. P. 228–240. doi: 10.1016/j.compositesb.2018.10.075.

8. Daniel J. J. Scientific investigation on the stress minimization of the RC thin roof structures using Finite element method of analysis // Materials Today: Proc. 2021. Vol. 45. P. 6270–6276. doi: 10.1016/j.matpr.2020.10.703.

9. Alanani M., Elshaer A. ANN-based optimization framework for the design of wind load resisting system of tall buildings // Engin. Structures. 2023. Vol. 285. P. 116032. doi: 10.1016/j.engstruct.2023.116032.

10. Design and evaluation of a prediction-based dynamic edge computing system / E. Liu, X. Deng, Z. Cao, H. Zhang // 2018 IEEE Global Communications Conf. (GLOBECOM). Abu Dhabi, United Arab Emirates: IEEE, 2018. P. 1–6. doi: 10.1109/GLOCOM.2018.8647199.

11. Raissi M., Perdikaris P., Karniadakis G. E. Physics-Informed Neural Networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations // J. of Computational Phys. 2019. Vol. 378. P. 686–707. doi: 10.1016/j.jcp.2018.10.045.

12. Scientific machine learning through Physics-Informed Neural Networks: where we are and what's next / S. Cuomo, V. S. Di Cola, F. Giampaolo, G. Rozza, M. Raissi, F. Piccialli // J. of Scientific Comp. 2022. Vol. 92, no. 3. Art. 88. P. 1–62. doi: 10.1007/s10915-022-01939-z.

13. Bastek J.-H., Kochmann D. M. Physics-Informed Neural Networks for shell structures // European J. of Mechan. – A/Solids. 2023. Vol. 97. P. 104849. doi: 10.1016/j.euromechsol.2022.104849.

14. E W., Yu B. The Deep Ritz Method: A Deep Learning-Based Numerical Algorithm for Solving Variational Problems // Communications in Math. and Statistics. 2018. Vol. 6, no 1. P. 1–12. doi: 10.1007/s40304-018-0127-z.

15. Decision tree-based machine learning to optimize the laminate stacking of composite cylinders for maximum buckling load and minimum imperfection sensitivity / H. N. R. Wagner, H. Köke, S. Dähne, S. Niemann, C. Hühne, R. Khakimova // Composite Structures. 2019. Vol. 220. P. 45–63. doi: 10.1016/j.compstruct.2019.02.103.

16. A machine learning method for buckling design of internally pressurized torispherical heads considering geometric imperfection / F. Liu, J. Yang, S. Weng, F.-Z. Xuan, J.-G. Gong // Thin-Walled Structures. 2023. Vol. 189. P. 110908. doi:10.1016/j.tws.2023.110908.

17. Application of artificial neural network to predict buckling load of thin cylindrical shells under axial compression / Z. ul R. Tahir, P. Manda, M. T. Adi, F. Naz // Engin. Structures. 2021. Vol. 248. P. 113221. doi: 10.1016/j.engstruct.2021.113221.

18. Prediction of compression buckling load and buckling mode of hat-stiffened panels using artificial neural network / Z. Sun, Z. Lei, R. Bai, H. Jiang, J. Zou, Y. Ma, C. Yan // *Engin. Structures*. 2021. Vol. 242. P. 112275. doi: 10.1016/j.engstruct.2021.112275.
19. Ribeiro J., Tavares S., Parente M. Stress-strain evaluation of structural parts using artificial neural networks // *Proc. of the Institution of Mechan. Engineers. Part L: J. of Materials Design and Appl.* 2021. P. 1271–1286. doi: 10.1177/1464420721992445.
20. Zgoda Iu. N. High performance modeling of the stress-strain state of thin-walled shell structures with the use of deep learning // *Scientific and Technical J. of Inform. Technol., Mechan. and Optics*. 2023. Vol. 23, no. 2. P. 430–435. doi: 10.17586/2226-1494-2023-23-2-430-435.
21. Zgoda Iu. N. Vozmozhnosti glubokogo obucheniya primenitel'no k zadache komp'yuternogo modelirovaniya tonkostennyh obolochechnyh konstrukcij // *Sb. tr. IV Mezhdunar. konf. po nejronnym setjam i nejrotehnologijam (NeuroNt'2023)*. SPb.: SPbGJeTU, 2023. S. 68–71. (In Russ.).
22. Svid-vo o reg. pr-my dlja JeVM № 2023612571 (RU). OptiShellX – programma dlja vysokoproizvoditel'no-go rascheta tonkostennyh obolochechnyh konstrukcij / Iu. N. Zgoda. Zjav. 27.01.23; opubl. 06.02.2023. (In Russ.).
23. Julia: A Fresh Approach to Numerical Computing / J. Bezanson, A. Edelman, S. Karpinski, V. B. Shah // *SIAM Rev.* 2017. Vol. 59, no. 1. P. 65–98. doi: 10.1137/141000671.
24. Karpov V. V., Semenov A. A. Bezrazmernye parametry v teorii podkrepennyh obolochek // *Vest. PNIPU. Mehanika*. 2015. № 3. S. 74–94. doi: 10.15593/perm.mech/2015.3.07. (In Russ.).
25. Semenov A. A., Leonov S. S. Metod nepreryvnogo prodolzheniya resheniya po nailuchshemu parametru pri raschete obolochechnyh konstrukcij // *Uchen. zap. Kazanskogo un-ta. Ser.: Fiziko-matematicheskie nauki*. 2019. T. 161, № 2. S. 230–249. doi: 10.26907/2541-7746.2019.2.230-249. (In Russ.).
26. Karpov V. V. Analiz algoritmov issledovaniya ustojchivosti tonkostennyh obolochek // *Izv. Saratovskogo un-ta. Novaja serija. Ser.: Matematika. Mehanika. Informatika*. 2012. T. 12, № 1. S. 63–69. doi: 10.18500/1816-9791-2012-12-1-63-69. (In Russ.).
-

Information about the author

Iurii N. Zgoda – 2nd category specialist of the Educational Center of Digital Competence, Saint Petersburg State University of Architecture and Civil Engineering, 2nd Krasnoarmeiskaya St., 4, St. Petersburg, 190005, Russia.
E-mail: yurii.zgoda@mail.ru
<https://orcid.org/0000-0001-6714-500X>

Статья поступила в редакцию 18.07.2024; принята к публикации после рецензирования 22.11.2024; опубликована онлайн 27.01.2025.

Submitted 18.07.2024; accepted 22.11.2024; published online 27.01.2025.
