

DOI: <https://doi.org/10.26896/1028-6861-2023-89-4-71-76>

НЕЙРОСЕТЕВАЯ АППРОКСИМАЦИЯ КРИВЫХ ДЕФОРМИРОВАНИЯ ПРИ ОДНООСНОМ РАСТЯЖЕНИИ ОБРАЗЦОВ ИЗ СТАЛИ И СИЛУМИНА

© Любовь Владимировна Хливненко¹, Владимир Васильевич Елисеев², Александр Михайлович Гольцев¹

¹ Воронежский государственный технический университет, Россия, Воронеж, Московский проспект, д. 14; e-mail: khlivnenko.lv@gmail.com

² Инженерное бюро «МАТТЕСТ», Россия, Воронеж, ул. Генерала Перхоровича, д. 6; e-mail: evv52@bk.ru

Статья поступила 20 июня 2022 г. Поступила после доработки 29 августа 2022 г. Принята к публикации 30 сентября 2022 г.

Цель исследования — разработка и апробация новой расчетной методики для решения задачи аппроксимации кривых деформирования при одноосном растяжении образцов из стали и силумина, позволяющей повысить качество моделирования. Представлена схема испытания на одноосное растяжение образцов из стали и силумина. Эксперимент на одноосное растяжение поставлен в лаборатории механических испытаний кафедры прикладной математики и механики Воронежского государственного технического университета. Экспериментальная кривая деформирования образца из стали аппроксимирована уравнением П. Людвига. Обсуждается вариант прогнозирования зависимости истинного напряжения по логарифмической деформации для рассматриваемой задачи с помощью предварительно обученной искусственной нейронной сети с архитектурой многослойного персептрона. Обучение нейросетевой модели выполнено методом RProp (resilient backpropagation). Программная реализация нейросетевого способа аппроксимации проведена в open source фреймворке для анализа данных — Knime Analytics Platform. Рассмотрена схема проекта для реализации многослойного персептрона, решающего задачу аппроксимации. Выполнено сравнение результатов моделирования по значениям среднеквадратической ошибки аппроксимации. Для образца из стали нейросетевая аппроксимация оказалась на порядок точнее, чем аппроксимация уравнением П. Людвига. Для образца из силумина нейросетевая аппроксимация выполнена с еще меньшим значением среднеквадратической ошибки, чем для образца из стали. Выявлено, что изменение архитектуры искусственной нейронной сети влияет на качество моделирования. При увеличении количества скрытых слоев точность аппроксимации повышается. Нейросетевая аппроксимация представляет собой эффективный способ решения задачи аналитического описания экспериментальных кривых деформирования и оставляет возможность использования универсальной методики для разнообразных материалов и видов испытаний.

Ключевые слова: аппроксимация кривых деформирования; одноосное растяжение; многослойный персептрон; искусственная нейронная сеть; нейросетевое прогнозирование.

NEURAL NETWORK APPROXIMATION OF DEFORMATION CURVES UNDER UNIAXIAL TENSION OF STEEL AND SILUMIN SPECIMENS

© Lyubov V. Khlivnenko,¹ Vladimir V. Eliseev,² Aleksandr M. Goltsev¹

¹ Voronezh State Technical University, 14, Moskovskiy prospekt, Voronezh, 394026, Russia; e-mail: khlivnenko.lv@mail.ru

² Engineering Bureau «MATTEST», 6, General Perkhovich ul., Voronezh, 394086, Russia; e-mail: evv52@bk.ru

Received June 20, 2022. Revised August 29, 2022. Accepted September 30, 2022.

The purpose of the study is developing and testing of the new computational technique for approximation of deformation curves of steel and silumin specimens under uniaxial tension. A scheme of testing steel and silumin specimens for uniaxial tensile is presented. The experiment was carried out in the mechanical testing laboratory of the Department of Applied Mathematics and Mechanics of the Voronezh State Technical University. The experimental deformation curve of a steel specimen was approximated by P. Ludwig's equation. Prediction of the true stress from the logarithmic strain using a pretrained artificial neural network with a multilayer perceptron architecture is discussed. The neural network model was trained using the RProp (resilient backpropagation) method. The software implementation of the neural network approximation was carried out in a framework of the open source for data analysis — Knime Analytics Platform. A scheme for the implementation of a multilayer perceptron that solves the approximation

problem is considered. The simulation results are compared by the values of the mean squared error (MSE) of the approximation. The neural network approximation is turned out to be an order of magnitude more accurate for the steel specimen than the approximation by the P. Ludwig equation. The neural network approximation provided even a smaller MSE value for a silumin specimen than that of a steel specimen. It is revealed that changing the architecture of an artificial neural network affects the quality of modeling. With an increase in the number of hidden layers, the accuracy of the approximation increases. Neural network approximation is an effective approach to solving the problem of the analytical description of experimental deformation curves and leaves the possibility of using a universal technique for a variety of materials and different types of tests.

Keywords: approximation of deformation curves; uniaxial tension; multilayer perceptron; artificial neural network; neural network forecasting.

Введение

Эффективность моделирования технологических операций не в последнюю очередь зависит от точности определения механических характеристик. Для решения этой задачи необходимы автоматизация процессов измерения и совершенные методы обработки результатов испытаний с использованием современных компьютерных систем и электронных датчиков измерений.

Валидность натурального эксперимента при одноосном растяжении можно проверить по совпадению экспериментальной и расчетной кривых деформирования, пределов прочности и текучести. По результатам сравнения итогов компьютерного моделирования и натурального эксперимента корректируют выбор модели пластичности материала.

В целях моделирования экспериментальные кривые деформирования, получаемые в табулированном виде, аппроксимируют. Это нетривиальная задача, поскольку для разных материалов и видов испытаний получают кривые разнообразной формы. Стандартных моделей для всех ситуаций не существует.

Для алюминиевых сплавов и при формовке в области больших деформаций, например оболоч-

чек из листовых металлов, чаще используют аппроксимацию Г. Свифта. Формовку профилей из металлов в области небольших деформаций, как правило, описывают уравнениями П. Людвига и Е. Воке.

Людвиг П. использовал двухпараметрическую аппроксимацию с помощью степенных функций:

$$\sigma_i = Ae_i^n, \quad (1)$$

где n — показатель деформационного упрочнения; A — коэффициент упрочнения; e — логарифмическая деформация; σ — истинное напряжение; i — номер измерения.

На рис. 1 показаны экспериментальная и расчетная, описанная формулой (1), кривые.

Аппроксимация позволяет экстраполировать кривую деформирования в зону развитых пластических деформаций. Основная проблема — появление значительной ошибки экстраполяции. Поэтому одной из стратегий совершенствования методов обработки результатов механических испытаний является повышение точности аппроксимации экспериментальных кривых деформирования.

Искусственные нейронные сети — универсальный инструмент для прогнозирования, успешно применяющийся для решения разнообразных задач экспериментальной механики.

В [1] описано нейросетевое моделирование реологии сплава АМГ6 в условиях проявления барьерного эффекта дисперсоидами и замедления динамических релаксационных процессов. Нейросетевой метод идентификации и анализа модели деформирования металлических конструкций в условиях ползучести ранее обсуждался в [2]. Комплекс нейросетевых решений в комбинации с моделью гауссовского процесса разработан авторами [3] для прогнозирования разрыва при ползучести.

Метод моделирования роста усталостной трещины, базирующийся на применении трех различных алгоритмов машинного обучения, включающих искусственные нейронные сети, пред-




Рис. 1. Экспериментальная кривая деформирования (синий цвет), полученная при растяжении образца из стали, и ее аппроксимация по уравнению П. Людвига (красный цвет)

Fig. 1. Experimental deformation curve (blue line) obtained upon tension a steel specimen and approximation by the Ludwigs equation (red line)




Рис. 2. Схема установки для проведения эксперимента на одноосное растяжение

Fig. 2. Scheme of the experimental setup for testing for uniaxial tension

ставлен в [4]. Авторы [5] использовали байесовскую нейронную сеть и методы машинного обучения для определения значений микромеханических и микроструктурных параметров, влияющих на направление и скорость распространения усталостной трещины.

В [6] исследованы модели прогнозирования площади расслаивания композитных материалов, основанные на методах машинного обучения. Рассмотрены линейная модель, машины опорных векторов и «случайный лес». В [7] описана разработка регрессионных и нейросетевых моделей для прогнозирования шероховатости поверхности при точении латуни (С23000) с использованием инструмента из быстрорежущей стали. Авторы [8] определяли с помощью нейросетевого моделирования и других методов машинного обучения значения механических характеристик плоских алюминиевых образцов, деформируемых в результате воздействия высоких температур, по фотографиям.

Цель данного исследования — разработка расчетных методик, базирующихся на методах машинного обучения, их программная реализация и экспериментальная проверка для решения задачи аппроксимации кривых деформирования при одноосном растяжении образцов из стали и силумина.

Материалы и методы исследования

Эксперимент на одноосное растяжение в лаборатории механических испытаний кафедры прикладной математики и механики Воронежского государственного технического университета проводят на универсальной испытательной




Рис. 3. Геометрия образца на одноосное растяжение

Fig. 3. Specimen geometry

машине Р-20 с гидроприводом. Растягивающее усилие и осевое удлинение фиксируют электронными аналоговыми датчиками, сигналы с которых поступают на карту оцифровки. Для обработки сигналов используют авторское программное обеспечение. Схема экспериментальной установки приведена на рис. 2.

Табулированную диаграмму растяжения получают в координатах удлинение Δl (мм) — растягивающее усилие P (Н) и пересчитывают в целях моделирования для координат логарифмическая деформация e — истинное напряжение σ :

$$e = \ln \frac{l}{l_0}, \quad \sigma = \frac{P}{F_0} \exp(e), \quad (2)$$

где l_0 и F_0 — начальные длина и площадь поперечного сечения образца; $l = l_0 + \Delta l$.

Форма и размеры образца для эксперимента на одноосное растяжение показаны на рис. 3.

Набор данных для моделирования представляет собой таблицу значений (X, Y) , полученную экспериментально. Аргументом (X) является логарифмическая деформация (e) , а результатом (Y) — соответствующее истинное напряжение (σ) .

Сравним аппроксимацию П. Людвига с аппроксимацией, полученной искусственной нейронной сетью с архитектурой многослойного персептрона. Компьютерные модели будем строить в open source фреймворке для анализа данных — Knime Analytics Platform (KNIME).

Программно реализуем многослойный персептрон и обучим его решению задачи аппроксимации кривой деформирования, представленной на рис. 1. Схема проекта в KNIME приведена на рис. 4.

Таблицу исходных данных (X, Y) свяжем с проектом с помощью узла *Excel Reader* через свойство *Configure*. Узел *Math Formula* служит для добавления в таблицу нового столбца данных *Prediction (Y)*, предобученного на результирующем столбце Y .




Рис. 4. Схема проекта в KNIME для реализации многослойного персептрона

Fig. 4. Scheme of the project in KNIME for the implementation of a multilayer perceptron




Рис. 5. График ошибок обучения многослойного персептрона

Fig. 5. Graph of the errors of training multilayer perceptron

Узел Normalizer выполняет нормализацию всех столбцов данных. Использован вариант Min-Max Normalization с выходным диапазоном нормализованных значений от 0 до 1. С помощью узла Column Filter в блок обучения сети подаются только исходные данные из столбцов (X, Y).

Обучение нейросети методом RProp происходит в узле *RProp MLP Learner*. RPROP (resilient backpropagation) — это вариант метода обратного распространения ошибки. Метод является одним из лучших по скорости обучения в классе локально-адаптивных алгоритмов обучения. В нем учтены изменения локального градиента для выбора размера и направления шага. Алгоритмы

обучения и функционирования обученной искусственной нейронной сети с архитектурой многослойного персептрона в режиме прогнозирования описаны в [9]. Методы оценки ошибок прогнозирования и иные методы машинного обучения приведены в [10].

В нашем исследовании построена сеть с пятью скрытыми слоями и 20 нейронами в каждом слое. Максимальное число обучающих эпох — 100. На рис. 5 показан график ошибок сети для узла *RProp MLP Learner* после завершения процесса обучения. Видно, что с ростом числа обучающих итераций ошибка сети уменьшается. Следовательно, процесс обучения сходится к некоторому стабильному набору значений весовых коэффициентов связи между нейронами. Рассчитанные значения доступны через свойство Neural Network узла *RProp MLP Learner*. Обученную модель можно применить для аппроксимации.

Таблицу исходных и расчетных данных получают через метод Classified Data узла *MultiLayer Perceptron Predictor*, предназначенного для использования обученной нейронной сети в режиме прогнозирования. В таблице появится новый столбец Prediction (Y), сгенерированный нейросетью и заполненный прогнозными значениями, также лежащими в диапазоне от 0 до 1.

Данные из столбцов X, Y, Prediction (Y) поступают в узел Denormalizer для перерасчета в исходный масштаб. С помощью метода Denormalized output можно вывести на экран исходные и расчетные данные. Фрагмент результирующей таблицы показан на рис. 6.

Значения среднеквадратической ошибки, коэффициента детерминации и других оценок ка-

Denormalized output - 0:12 - Denormalizer

File Edit Hilite Navigation View

Table "default" - Rows: 4445 Spec - Columns: 3 Properties Flow Variables

Row ID	D X	D Y	D Prediction (Y)
Row746	0.05	455.395	457.887
Row747	0.051	455.61	458.08
Row748	0.051	455.815	458.276
Row749	0.051	456.005	458.469
Row750	0.051	456.209	458.661

Рис. 6. Фрагмент исходных и прогнозных данных, рассчитанных по нейросетевой модели

Fig. 6. A fragment of the initial and predictive data calculated using a neural network model

чества моделирования доступны через свойство Statistics компонента Numeric Scorer.

Обсуждение результатов

Для кривой, представленной на рис. 1, аппроксимация по уравнению П. Людвига имеет вид

$$Y_{predict} = AX^n, \quad (3)$$

где показатель деформационного упрочнения $n = 0,2727$ со среднеквадратическим отклонением 0,0007, а коэффициент упрочнения $A = 1152,4141$ со среднеквадратическим отклонением 5,3510. Данные значения получены методом наименьших квадратов с помощью специально разработанного для этих целей программного обеспечения.

Сравним результаты моделирования по значениям среднеквадратической ошибки MSE (Mean squared error), определяемой формулой

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - Y_{predict i})^2, \quad (4)$$

где n — количество наблюдений; в нашем примере $n = 4445$. Для аппроксимации П. Людвига $MSE = 48,2872$.

Чем меньше значение MSE, тем лучше аналитическая формула описывает исходные данные.

Для многослойного персептрона, обученного на том же наборе исходных данных, $MSE = 4,634$, что на порядок меньше значения соответствующего показателя для аппроксимации П. Людвига.

График аппроксимации кривой деформирования для одноосного растяжения образца из стали, показанной на рис. 1, с помощью многослойного персептрона приведен на рис. 7.

Сравнивая разные аппроксимации одной и той же кривой деформирования, представленные




Рис. 7. Экспериментальная кривая деформирования (синий цвет), полученная при растяжении образца из стали, и ее аппроксимация многослойным персептроном (красный цвет)

Fig. 7. Experimental deformation curve (blue line) obtained upon tension for a steel specimen and approximation by a multilayer perceptron (red line)




Рис. 8. Экспериментальная кривая деформирования (синий цвет), полученная при растяжении образца из силумина, и ее аппроксимация многослойным персептроном (красный цвет)

Fig. 8. Experimental deformation curve (blue line) obtained upon tension for a silumin specimen and approximation by a multilayer perceptron (red line)

на рис. 1 и 7, а также значения MSE, можно сделать вывод о том, что наиболее точно экспериментальную кривую описывает нейросетевая модель.

Проверим универсальность и качество нейросетевого способа моделирования, применив описанную выше модель для аппроксимации кривой деформирования, полученной при растяжении образца (см. рис. 3) из силумина.

Для обучения многослойного персептрона с пятью скрытыми слоями и 20 нейронами в каждом слое использована выборка объема $n = 4313$. Значение среднеквадратической ошибки прогнозирования $MSE = 0,162$.

Изменение архитектуры сети в сторону увеличения числа скрытых слоев уменьшает значение MSE. В случае обучения многослойного персептрона с семью скрытыми слоями и 20 нейронами в каждом слое значение $MSE = 0,056$.

График аппроксимации кривой деформирования для одноосного растяжения образца из силумина с помощью многослойного персептрона с семью скрытыми слоями показан на рис. 8.

Заключение

1. Представлена схема испытания на одноосное растяжение образцов из стали и силумина. Экспериментальная кривая деформирования образца из стали аппроксимирована уравнением П. Людвига с $MSE = 48,2872$ при объеме выборки $n = 4445$.

2. Разработан и программно реализован в KNIME способ аналитического описания экспериментальной кривой растяжения с помощью предварительно обученной искусственной нейронной сети с архитектурой многослойного персептрона.

3. Установлено, что нейросетевая аппроксимация на порядок точнее, чем аппроксимация П. Людвига. Для многослойного персептрона с пятью скрытыми слоями и 20 нейронами в каждом слое значение $MSE = 4,634$ для образца из стали при объеме выборки $n = 4445$ и $MSE = 0,162$ для образца из силумина при объеме выборки $n = 4313$.

4. Выявлено, что изменение архитектуры искусственной нейронной сети влияет на качество моделирования. При увеличении количества скрытых слоев точность аппроксимации повышается. При изменении числа скрытых слоев с 5 до 7 для образца из силумина значение MSE уменьшилось с 0,162 до 0,056.

5. Нейросетевая аппроксимация представляет собой эффективный способ решения задачи аналитического описания экспериментальных кривых деформирования и оставляет возможность использования универсальной методики для разнообразных материалов и видов испытаний.

ЛИТЕРАТУРА

1. Смирнов А. С., Коновалов А. В., Канакин В. С. Нейросетевое моделирование реологии сплава АМГ6 в условиях проявления барьерного эффекта дисперсоидами и замедления динамических релаксационных процессов / *Diagnostics, Resource and Mechanics of materials and structures*. 2020. Issue 6. С. 10 – 26. DOI: 10.17804/2410-9908.2020.6.010-026
2. Васильев А. Н., Кузнецов Е. Б., Леонов С. С. Нейросетевой метод идентификации и анализа модели деформирования металлических конструкций в условиях ползучести / *Современные информационные технологии и ИТ-образование*. 2015. Т. 2. № 11. С. 360 – 369.
3. Chatzidakis S., Alamaniotis M., Tsoukalas L. H. Creep Rupture Forecasting: A Machine Learning Approach to Useful Life Estimation / *International Journal of Monitoring and Surveillance Technologies Research*. 2014. N 2. P. 1 – 25. DOI: 10.4018/ijmstr.2014040101
4. Wang H., Zhang W., Sun F. and Zhang W. A comparison study of machine learning based algorithms for fatigue crack growth calculation / *Materials*. 2017. N 10. P. 543. DOI: 10.3390/ma10050543

5. Rovinelli A., Sangid M. D., Proudhon H. and Ludwig W. Using machine learning and a data-driven approach to identify the small fatigue crack driving force in polycrystalline materials / *Computational Materials*. 2018. N 4. Article number 35. DOI: 10.1038/s41524-018-0094-7
6. Liu H., Liu S., Liu Z., et al. Prognostics of damage growth in composite materials using machine learning techniques / *IEEE International Conference on Industrial Technology*. 2017. P. 1042 – 1047. DOI: 10.1109/ICIT.2017.7915505
7. Hanief M., Wani M. F. Artificial neural network and regression-based models for prediction of surface roughness during turning of red brass (C23000) / *Journal of Mechanical Engineering and Sciences (JMES)*. 2016. Vol. 10. Issue 1. P. 1835 – 1845. DOI: 10.15282/jmes.10.1.2016.8.0176
8. Shevchenko E. C., Teraud W. V. Modelling of mechanical characteristics of deformable flat specimens under creep by machine learning methods / *Journal of Mechanical Engineering and Sciences (JMES)*. 2021. Vol. 14. Issue 1. P. 6393 – 6405.
9. Хливненко Л. В., Пятакович Ф. А. Практика нейросетевого моделирования: учебное пособие для вузов. Изд. 2-е, стер. — СПб.: Лань, 2021. — 200 с.
10. Нильсен Э. Практический анализ временных рядов: прогнозирование со статистикой и машинное обучение. — СПб.: ООО «Диалектика», 2021. — 544 с.

REFERENCES

1. Smirnov A. S., Konovalov A. V., Kanakin V. S. Neural network modeling of the rheology of the AlMg6 alloy under the dispersoid barrier effect and the inhibition of dynamic relaxation processes / *Diagnostics, Resource and Mechanics of materials and structures*. 2020. Issue 6. P. 10 – 26 [in Russian]. DOI: 10.17804/2410-9908.2020.6.010-026
2. Vasilyev A. N., Kuznetsov E. B., Leonov S. S. Neural network method of identification and analysis of the model of deformation of metal structures under creep conditions / *Sovr. Inf. Tekhnol. IT-obrazov*. 2015. N 11. Vol. 2. P. 360 – 369 [in Russian].
3. Chatzidakis S., Alamaniotis M., Tsoukalas L. H. Creep Rupture Forecasting: A Machine Learning Approach to Useful Life Estimation / *International Journal of Monitoring and Surveillance Technologies Research*. 2014. N 2. P. 1 – 25. DOI: 10.4018/ijmstr.2014040101
4. Wang H., Zhang W., Sun F. and Zhang W. A comparison study of machine learning based algorithms for fatigue crack growth calculation / *Materials*. 2017. N 10. P. 543. DOI: 10.3390/ma10050543
5. Rovinelli A., Sangid M. D., Proudhon H. and Ludwig W. Using machine learning and a data-driven approach to identify the small fatigue crack driving force in polycrystalline materials / *Computational Materials*. 2018. N 4. Article number 35. DOI: 10.1038/s41524-018-0094-7
6. Liu H., Liu S., Liu Z., et al. Prognostics of damage growth in composite materials using machine learning techniques / *IEEE International Conference on Industrial Technology*. 2017. P. 1042 – 1047. DOI: 10.1109/ICIT.2017.7915505
7. Hanief M., Wani M. F. Artificial neural network and regression-based models for prediction of surface roughness during turning of red brass (C23000) / *Journal of Mechanical Engineering and Sciences (JMES)*. 2016. Vol. 10. Issue 1. P. 1835 – 1845. DOI: 10.15282/jmes.10.1.2016.8.0176
8. Shevchenko E. C., Teraud W. V. Modelling of mechanical characteristics of deformable flat specimens under creep by machine learning methods / *Journal of Mechanical Engineering and Sciences (JMES)*. 2021. Vol. 14. Issue 1. P. 6393 – 6405.
9. Khlivnenko L. V., Pyatakovich F. A. Practice of neural network modeling: a textbook for universities. 2nd edition. — St. Petersburg: Lan', 2021. — 200 p. [in Russian]
10. Nielsen E. Practical analysis of time series: forecasting with statistics and machine learning. — St. Petersburg: Dialektika, 2021 — 544 p. [in Russian].