

## МНОГОКРИТЕРИАЛЬНАЯ ОПТИМИЗАЦИЯ ПАРАМЕТРОВ ЛАЗЕРНОЙ РЕЗКИ КВАРЦЕВОГО СТЕКЛА С ПРИМЕНЕНИЕМ НЕЙРОСЕТЕВОГО МОДЕЛИРОВАНИЯ И ГЕНЕТИЧЕСКОГО АЛГОРИТМА

Ю.В. Никитюк, В.А. Прохоренко, А.И. Кулыба

*Гомельский государственный университет имени Франциска Скорины*

## MULTI-CRITERIA OPTIMIZATION OF QUARTZ GLASS LASER CUTTING PARAMETERS USING NEURAL NETWORK SIMULATION AND GENETIC ALGORITHM

Y.V. Nikitjuk, V.A. Prokhorenko, A.I. Kulyba

*Francisk Skorina Gomel State University*

**Аннотация.** При помощи нейросетевого моделирования и с использованием генетического алгоритма определены значения технологических параметров, обеспечивающие эффективную лазерную резку кварцевого стекла при воздействии на обрабатываемое изделие лазерного пучка с длиной волны, равной 10,6 мкм, и хладагента. Выполнена многокритериальная оптимизация лазерной резки кварцевых пластин по критериям максимума растягивающих напряжений и максимума скорости обработки. Описаны алгоритмы выбора оптимальной архитектуры нейронных сетей.

**Ключевые слова:** нейросетевое моделирование, лазерная резка, генетический алгоритм, оптимизация параметров.

**Для цитирования:** Никитюк, Ю.В. Многокритериальная оптимизация параметров лазерной резки кварцевого стекла с применением нейросетевого моделирования и генетического алгоритма / Ю.В. Никитюк, В.А. Прохоренко, А.И. Кулыба // Проблемы физики, математики и техники. – 2023. – № 3 (56). – С. 26–31. – DOI: [https://doi.org/10.54341/20778708\\_2023\\_3\\_56\\_26](https://doi.org/10.54341/20778708_2023_3_56_26). – EDN: BXVAMJ

**Abstract.** Using neural network modeling and a genetic algorithm, the values of technological parameters were determined that ensure efficient laser cutting of quartz glass when the workpiece is exposed to a laser beam with a wavelength of 10,6  $\mu\text{m}$  and a coolant. The multi-criteria optimization of laser cutting of quartz plates was performed according to the criteria of maximum tensile stresses and maximum processing speed. The algorithms for choosing the optimal architecture of neural networks are described.

**Keywords:** neural network modeling, laser cutting, genetic algorithm, parameter optimization.

**For citation:** Nikitjuk, Y.V. Multi-criteria optimization of quartz glass laser cutting parameters using neural network simulation and genetic algorithm / Y.V. Nikitjuk, V.A. Prokhorenko, A.I. Kulyba // Problems of Physics, Mathematics and Technics. – 2023. – № 3 (56). – P. 26–31. – DOI: [https://doi.org/10.54341/20778708\\_2023\\_3\\_56\\_26](https://doi.org/10.54341/20778708_2023_3_56_26) (in Russian). – EDN: BXVAMJ

### Введение

Среди основных методов разделения хрупких неметаллических материалов, таких как кварцевые стекла, выделяются резка при помощи алмазных дисков, механическое и лазерное скрайбирование. При этом управляемое лазерное раскалывание является наиболее эффективным способом резки таких материалов. Применение этой технологии основано на создании определенного распределения термоупругих напряжений внутри материала, что обеспечивает формирование лазерно-индуцированных трещин с заданными параметрами. Преимуществами данной технологии являются высокая точность и скорость нанесения лазерных разрезов [1]–[3].

В настоящее время исследования по моделированию лазерной обработки материалов успешно применяют искусственные нейронные сети [4]–[6]. Для повышения эффективности лазерных технологий важно оптимизировать соответствующие технологические параметры,

примеры такого использования генетических алгоритмов представлены в работах [7]–[9]. Генетические алгоритмы представляют собой одну из форм эволюционных методов, основанных на коллективном обучении внутри популяции и имитации естественного отбора. Они обеспечивают поиск оптимальных решений путем наследования и усиления полезных свойств множества объектов в процессе имитации эволюции [10], [11].

В данной работе была выполнена многокритериальная оптимизация процесса лазерной резки кварцевых пластин методом управляемого раскалывания с использованием нейросетевого моделирования и авторской версии модифицированного генетического алгоритма (МГА) [10].

### 1 Построение нейросетевых аппроксиматоров

Факторами в рассматриваемой задаче являются:  $V$  – скорость резки,  $A$  и  $B$  – полуоси эллиптического лазерного пучка,  $P$  – мощность лазерного

излучения. При этом определялись следующие отклики:  $\sigma_{yy}$  – максимальные напряжения растяжения,  $T$  – максимальная температура в зоне лазерного воздействия. В работе применялось нейросетевое моделирование откликов  $\sigma_{yy}$  и  $T$ .

Для формирования массива данных и данных для тестирования нейронных сетей были использованы расчеты температурных полей и полей термоупругих напряжений, полученные в работе [6]. Все данные были нормализованы и приведены к диапазону  $[0, 1]$ . Нейронные сети, алгоритмы их обучения и кросс-валидации реализованы с использованием библиотеки Keras на языке Python.

При решении задач средствами нейросетевого моделирования важной проблемой является выбор оптимальной архитектуры нейронной сети. Задача выбора структуры нейронной сети является сложной. Простейшим подходом к решению этой проблемы является реализация схем перебора архитектур-кандидатов с их последующей кросс-валидацией (рисунок 1.1).

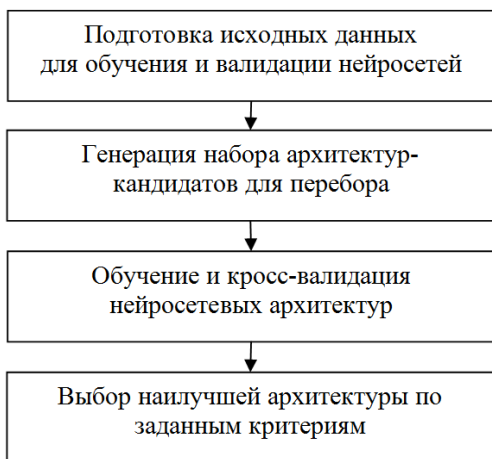


Рисунок 1.1 – Схема алгоритма выбора оптимальной архитектуры нейронной сети с применением метода перебора




Рисунок 1.2 – Тепловые карты распределений среднеквадратичной ошибки (MSE) для трехслойных архитектур-кандидатов нейросетевых аппроксиматоров откликов  $\sigma_{yy}$  (а) и  $T$  (б)

При выборе оптимальных архитектур нейросетей для аппроксимации откликов  $\sigma_{yy}$  и  $T$  сравнивались трехслойные перцептроны различных конфигураций. Количество нейронов в первом и втором скрытых слоях перебиралось в диапазоне от 8 до 96 с шагом 4. Для каждой архитектуры-кандидата был осуществлен пятикратный процесс кросс-валидации с разделением исходных данных на пять частей и предварительным случайным перемешиванием данных. Метрики MSE (среднеквадратичная ошибка), MAE (средняя абсолютная ошибка),  $R^2$  (коэффициент детерминации) усреднялись по всем экспериментам.

На рисунках 1.2 и 1.3 показаны тепловые карты распределений MSE и  $R^2$  для аппроксиматоров откликов  $\sigma_{yy}$  и  $T$ .

В таблице 1.1 приведены значения метрик для наилучших архитектур аппроксиматора отклика  $T$ .

Таблица 1.1 – Значения метрик MSE, MAE и  $R^2$  для наилучших архитектур-кандидатов аппроксиматора максимальной температуры  $T$ .

Архитектура нейросети	MSE	MAE	$R^2$	Количество эпох обучения
88-84-1	$4,103 \cdot 10^{-5}$	0,002674	0,9969	608
88-88-1	$4,137 \cdot 10^{-5}$	0,002663	0,9968	595
96-76-1	$4,490 \cdot 10^{-5}$	0,002874	0,9960	559
88-80-1	$4,507 \cdot 10^{-5}$	0,003218	0,9959	580
96-56-1	$4,674 \cdot 10^{-5}$	0,0030257	0,9965	625




Рисунок 1.3 – Тепловые карты распределений коэффициента детерминации ( $R^2$ ) для трехслойных архитектур-кандидатов нейросетевых аппроксиматоров откликов  $\sigma_{yy}$  (а) и  $T$  (б)

В ходе численных экспериментов было установлено, что лучшие результаты при аппроксимации  $\sigma_{yy}$  показывает искусственная нейронная сеть с архитектурой [64-56-1], а при аппроксимации температуры  $T$  – искусственная нейронная сеть с архитектурой [88-84-1].

Следует, однако, отметить, что в случае глубоких нейронных сетей имплементация алгоритмов, основанных на переборе, становится проблематичной в силу большой размерности пространства поиска и отсутствия очевидных критериев перебора архитектур. Использование эволюционных подходов и генетических алгоритмов может частично автоматизировать задачу поиска оптимальной архитектуры.

В данной работе использован эволюционный алгоритм подбора нейросетевых архитектур для решения задачи выбора оптимальной архитектуры аппроксиматора  $\sigma_{yy}$ . Схема алгоритма показана на рисунке 1.4.

В использованном в данной работе алгоритме применена схема кодирования архитектур, мутаций и скрещиваний геномов, основанная на алгоритме NEAT [11]. В отличие от NEAT, предложенный алгоритм не выполняет оптимизацию эволюционными методами весов связей в нейросети и оперирует не единичными нейронами в качестве узлов, а модулями, которые могут представлять собой произвольно заданный набор слоёв. В данной работе использованы модули, представляющие собой полносвязные слои с количеством нейронов от 4 до 16 и функцией активации ReLu. Применялись мутации двух типов: добавление узла и добавление связи между узлами. В качестве процедуры оценки качества генома в контексте решаемой задачи была использована кросс-валидация с разделением данных на три части и вычислением усредненной среднеквадратичной ошибки MSE для всех членов

популяции. При этом 20% лучших членов популяции переходили в следующее поколение, остальные геномы генерировались путем скрещивания лучших геномов и применения случайных мутаций с вероятностью  $p = 0,5$ .

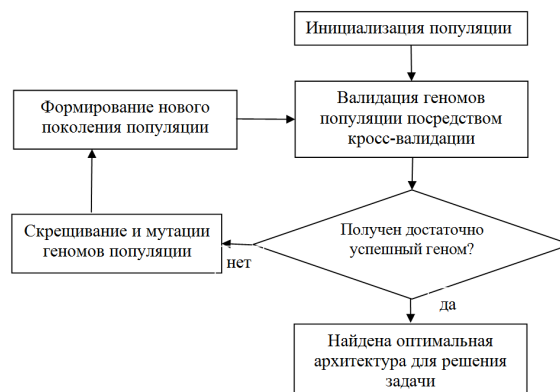


Рисунок 1.4 – Схема эволюционного алгоритма выбора оптимальной архитектуры нейросети




Рисунок 1.5 – Уменьшение MSE для лучшего генома популяции при использовании эволюционного алгоритма поиска оптимальной архитектуры нейросети

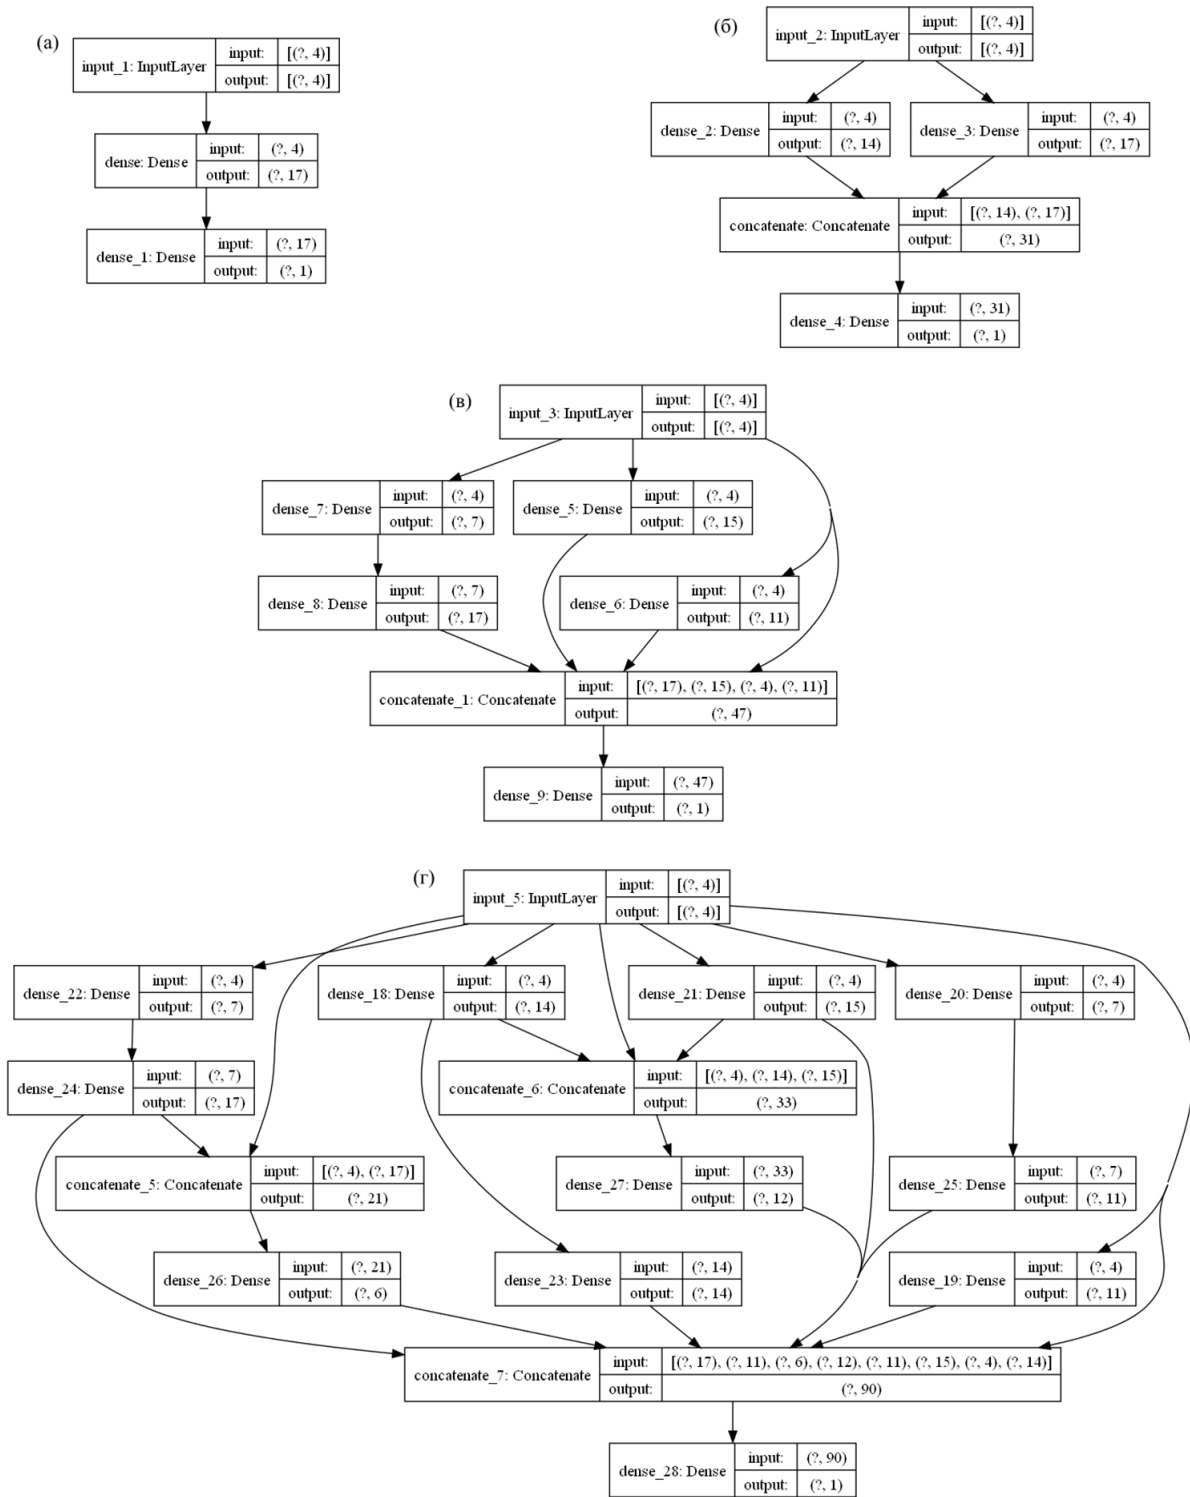


Рисунок 1.6 – Эволюция архитектуры нейросетей на протяжении 5 поколений (буквой *a*) обозначена исходная архитектура нейронной сети, буквами *б*), *в*), *г*) обозначены архитектуры лучших нейросетей для 2, 4 и 5 поколений

На рисунке 1.5 показана динамика изменения среднего значения MSE для 5 поколений в популяции размером 50 геномов. На рисунке 1.6 показана эволюция нейросетевой архитектуры на протяжении 5 поколений.

Полученная в процессе реализации эволюционного алгоритма архитектура нейросети по

результатам кросс-валидации демонстрирует значения усредненных метрик оценки качества, сравнимые со значениями архитектур, отобранных с помощью алгоритма перебора ( $MSE = 3,827 \cdot 10^{-5}$ ;  $MAE = 3,861 \cdot 10^{-3}$ ;  $R^2 = 0,996$ ).

## 2 Определение оптимальных параметров процесса лазерной резки кварцевых пластин

С использованием нейронных сетей с архитектурами [64-56-1] для аппроксимации  $\sigma_{yy}$  и [88-84-1] для аппроксимации  $T$  был осуществлен поиск значений факторов, обеспечивающих максимальные значения напряжений  $\sigma_{yy}$  при условии  $V \rightarrow \max$  и ограничения на значение температуры  $T < 1473 K$ . Также были введены ограничения на выход значений факторов за пределы диапазонов в обучающей выборке нейросетевых аппроксиматоров.

На языке Python была создана авторская версия модифицированного генетического алгоритма (МГА) [10]. В основе процесса генерации новых поколений популяции лежал метод скрещивания геномов, представленный в [10], при этом дополнительно была реализована мутация геномов путем внесения случайных изменений в факторы в пределах диапазона  $[0.0001, 0.1]$  с вероятностью  $p = 0,5$ .

Целевая функция включала в себя значения предсказанных нейросетевыми аппроксиматорами оценок  $\sigma_{yy}$  и  $T$  и фактора  $V$ , а также штрафы за выход за пределы допустимых диапазонов значений факторов и значений максимальных температур:

$$L(A, B, V, P) = -(\alpha_1 \sigma_{yy} + \alpha_2 V) + \beta_1 E_1 + \beta_2 E_2 + \beta_3 E_4 + \beta_4 E_4 + \beta_5 E_5,$$

$$E_1 = \begin{cases} 1, & A \notin [0, 1], \\ 0, & A \in [0, 1]; \end{cases} \quad E_2 = \begin{cases} 1, & B \notin [0, 1], \\ 0, & B \in [0, 1]; \end{cases}$$

$$E_3 = \begin{cases} 1, & V \notin [0, 1], \\ 0, & V \in [0, 1]; \end{cases} \quad E_4 = \begin{cases} 1, & P \notin [0, 1], \\ 0, & P \in [0, 1]; \end{cases}$$

$$E_5 = \begin{cases} 1, & T \geq 1473K, \\ 0, & T < 1473K; \end{cases}$$

$$\alpha_1 = \alpha_2 = 0,5; \quad \beta_i = 1,0, \quad i = \overline{1,5}.$$

Рассмотрена также альтернативная целевая функция:

$$L(A, B, V, P) = -\sqrt{(\alpha_2 \sigma_{yy})^2 + (\alpha_2 V)^2} + \beta_1 E_1 + \beta_2 E_2 + \beta_3 E_4 + \beta_4 E_4 + \beta_5 E_5,$$

$$E_1 = \begin{cases} 1, & A \notin [0, 1], \\ 0, & A \in [0, 1]; \end{cases} \quad E_2 = \begin{cases} 1, & B \notin [0, 1], \\ 0, & B \in [0, 1]; \end{cases}$$

$$E_3 = \begin{cases} 1, & V \notin [0, 1], \\ 0, & V \in [0, 1]; \end{cases} \quad E_4 = \begin{cases} 1, & P \notin [0, 1], \\ 0, & P \in [0, 1]; \end{cases}$$

$$E_5 = \begin{cases} 1, & T \geq 1473K, \\ 0, & T < 1473K; \end{cases}$$

$$\alpha_1 = \alpha_2 = 0,5; \quad \beta_i = 1,0, \quad i = \overline{1,5}.$$

Процесс многокритериальной оптимизации с применением авторского генетического алгоритма представлен на рисунке 7. На обоих графиках видно монотонное уменьшение значений целевой функции (сплошная линия) для лучшего генома популяции (точки  $(A, B, V, P)$ ). Увеличение среднего значения целевой функции по популяции (пунктирная линия) в конце работы алгоритма объясняется приближением геномов к заданным границам (в частности, по температуре) и, соответственно, штрафами за выход  $\beta_i E_i$ . Существенной разницы в скорости сходимости и качестве алгоритмов при сравнении приведенных целевых функций не обнаружено.

В результате применения генетического алгоритма найдены оптимальные значения факторов, приведенные в таблице 2.1. В скобках приведены значения параметров, полученные в результате конечно-элементного расчета процесса лазерной резки кварцевой пластины с оптимальными значениями факторов, определенными в результате применения МГА. Показано, что установленные аппроксиматорами и МГА значения напряжения  $\sigma_{yy}$  и температуры  $T$ , определены с погрешностями 0,1% и 2,5% соответственно.

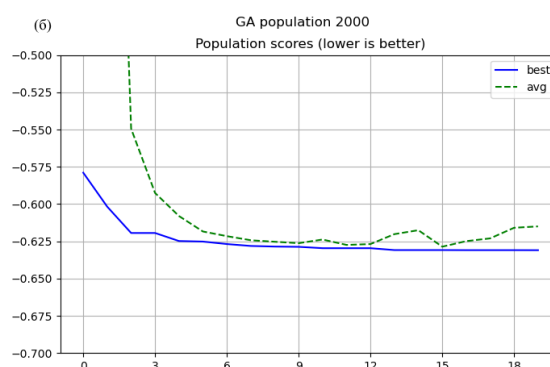
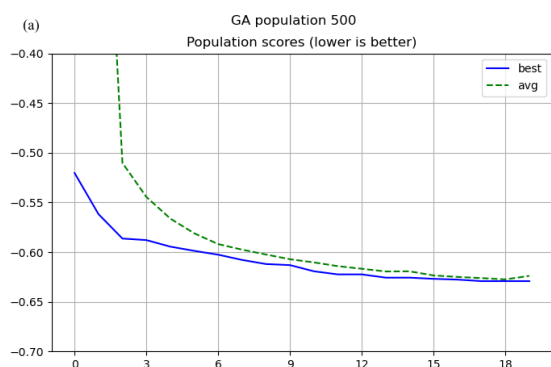


Рисунок 2.1 – Процесс сходимости генетического алгоритма при решении задачи многокритериальной оптимизации параметров раскалывания кварцевых пластин с размером популяции 500 (а) и размером популяции 2000 (б)

Таблица 2.1 – Результаты многокритериальной оптимизации

$V$ , мм/с	$A$ , мм	$B$ , мм	$P$ , Вт	$T$ , К	$\sigma_{\text{лп}}$ , МПа
69,9	0,00135	0,00080	299,9	1472,45 (1435,31)	7,24 (7,23)

### Заключение

В работе выполнена многокритериальная оптимизация откликов процесса лазерной резки кварцевых пластин с применением нейросетевого моделирования. Определены оптимальные значения факторов лазерной резки кварцевых пластин и установлено соответствие между построенной моделью и результатами конечно-элементного анализа. Описаны алгоритмы выбора оптимальной архитектуры нейронной сети методом перебора и на базе эволюционных методов. Определены оптимальные архитектуры нейронных сетей для аппроксимации максимума растягивающих напряжений и максимума температуры при выполнении лазерной резки кварцевых пластин.

### ЛИТЕРАТУРА

1. *Two-beam laser thermal cleavage of brittle nonmetallic materials* / S.V. Shalupaev, E.B. Shershnev, Y.V. Nikityuk, A.A. Sereda // Journal of Optical Technology. – 2006. – Vol. 73, № 5. – P. 356–359. – DOI: 10.1364/JOT.73.000356
2. *Features of controlled laser thermal cleavage of crystalline silicon* / A.N. Serdyukov, S.V. Shalupaev, Y.V. Nikityuk // Crystallography Reports. – 2010. – Vol. 55, № 6. – P. 933–937. – DOI: 10.1134/S1063774510060064
3. *Features of controlled laser thermal cleavage of crystal quartz* / A.N. Serdyukov, E.B. Shershnev, Y.V. Nikityuk [et al.] // Crystallography Reports. – 2012. – Vol. 57, № 6. – P. 792–797. – DOI: 10.1134/S1063774512060120.
4. *Determination of the parameters of two-beam laser splitting of silicate glasses using regression and neural network models* / Y.V. Nikityuk, A.N. Serdyukov, I.Y. Aushev // Journal of the Belarusian State University. Physics. – 2022. – № 1. – P. 35–43. – DOI: 10.33581/2520-2243-2022-1-35-43.

5. *Characterization of Laser Welding of Steel 30XГCH2A by Combining Artificial Neural Networks and Finite Element Method* / Y. Nikityuk, G. Bayevich, V. Myshkovets [et al.] // Lecture Notes in Networks and Systems. – 2022. – Vol. 422. – P. 273–279. – DOI: 10.1007/978-981-19-0379-3\_28.

6. *Применение искусственных нейронных сетей и метода конечных элементов для определения параметров обработки кварцевых золь-гель стекол эллиптическими лазерными пучками* / Ю.В. Никитюк, А.Н. Сердюков, В.А. Прохоренко, И.Ю. Аушев // Проблемы физики, математики и техники. – 2021. – № 3 (48). – С. 30–36.

7. *Nikityuk, Y.V. Optimization of two-beam laser cleavage of silicate glass* / Y.V. Nikityuk, A.N. Serdyukov, I.Y. Aushev // Journal of Optical Technology. – 2022. – Vol. 89, № 2. – P. 121–125. – DOI: 10.1364/JOT.89.000121.

8. *Оптимизация параметров двухлучевого ассиметричного лазерного раскалывания силикатного стекла* / Ю.В. Никитюк, А.А. Серета, А.Н. Сердюков [и др.] // Оптический журнал. 2023. – Т. 90, № 6. – С. 15–24. – DOI: <http://doi.org/10.17586/1023-5086-2023-90-06-15-24>.

9. *Красновская, С.В. Обзор возможностей оптимизационных алгоритмов при моделировании конструкций компрессорно-конденсаторных агрегатов методом конечных элементов* / С.В. Красновская, В.В. Напрасников // Весці Нацыянальнай акадэміі навук Беларусі. Серыя фізіка-тэхнічных навук. – 2016. – № 2. – С. 92–98.

10. *Очков, В.Ф. Mathcad 14 для студентов и инженеров: русская версия* / В.Ф. Очков. – БХВ-Петербург, 2009. – 512 с.

11. *Stanley, K.O. Evolving Neural Networks Through Augmenting Topologies* / K.O. Stanley, R. Miikkulainen // Evolutionary Computation. – 2002. – № 10 (2). – P. 99–127.

Поступила в редакцию 14.06.2023.

### Информация об авторах

Никитюк Юрий Валерьевич – к.ф.-м.н., доцент  
 Прохоренко Владислав Александрович – старший преподаватель  
 Кулыба Антон Игоревич – аспирант