

Научный журнал «Костюмология» / Journal of Clothing Science <https://kostumologiya.ru>

2026, Том 11, № 2 / 2026, Vol. 11, Iss. 2 <https://kostumologiya.ru/issue-2-2026.html>

URL статьи: <https://kostumologiya.ru/PDF/28TLKL226.pdf>

2.6.16. Технология производства изделий текстильной и легкой промышленности (технические науки)

Ссылка для цитирования этой статьи:

Орлов, А. В. Прогнозирование физико-механических свойств иглопробивных нетканых материалов на основе нейросетевого моделирования / А. В. Орлов, Ю. С. Шустов // Костюмология. — 2026. — Т. 11. — № 2. —

URL: <https://kostumologiya.ru/PDF/28TLKL226.pdf>.

For citation:

Orlov A.V., Shustov Yu.S. Prediction of physical and mechanical properties of needle-punched nonwoven materials based on neural network modeling. *Journal of Clothing Science*. 2026;11(2): 28TLKL226. Available at:

<https://kostumologiya.ru/PDF/28TLKL226.pdf>. (In Russ., abstract in Eng.).

УДК 677.076:004.032.26

Орлов Александр Васильевич

ФГБОУ ВО «Российский государственный университет имени А. Н. Косыгина
(Технологии. Дизайн. Искусство)», Москва, Россия

Аспирант

E-mail: metroid.prime@yandex.ru

РИНЦ: https://elibrary.ru/author_profile.asp?id=1157673

Шустов Юрий Степанович

ФГБОУ ВО «Российский государственный университет имени А. Н. Косыгина
(Технологии. Дизайн. Искусство)», Москва, Россия

Профессор, заведующий кафедры «Материаловедения и товарной экспертизы»

Доктор технических наук, профессор

E-mail: 6145263@mail.ru

РИНЦ: https://elibrary.ru/author_profile.asp?id=484967

Прогнозирование физико-механических свойств иглопробивных нетканых материалов на основе нейросетевого моделирования

Аннотация. В статье изложены результаты исследования, направленного на разработку системы нейросетевого прогнозирования физико-механических свойств иглопробивных термоскрепленных нетканых материалов обувного назначения из регенерированного волокнистого сырья. Актуальность работы связана с необходимостью предварительной оценки разрывной нагрузки и разрывного удлинения нетканых полотен на этапе выбора волокнистого состава и структурно-технологических параметров, поскольку проведение полного комплекса опытных выработок и лабораторных испытаний требует значительных временных и материальных затрат. Цель исследования состояла в построении и проверке нейросетевых моделей, позволяющих рассчитывать физико-механические свойства материала по заданным параметрам сырья, структуры полотна и процесса иглопрокалывания. Практическая реализация прогнозирования реализована программной среде Matlab с применением модуля Deep Learning Toolbox. Авторами сформирована экспериментальная база данных по 16 образцам иглопробивных нетканых материалов. В качестве входных параметров использованы поверхностная плотность, волокнистый состав, толщина полотна, глубина прокалывания и плотность прокалывания. В качестве выходных параметров рассматривались разрывная нагрузка и разрывное удлинение в продольном и поперечном направлениях. Для каждого выходного показателя построена отдельная нейросетевая модель. Авторами выполнена оценка точности прогнозирования и

проведено сопоставление ошибки модели с экспериментальной вариативностью. Установлено высокое согласование расчетных и экспериментальных данных. Показано, что разработанная система нейросетевого прогнозирования может применяться как расчетный инструмент при предварительном проектировании иглопробивных нетканых материалов и выборе рациональных структурно-технологических параметров.

Ключевые слова: иглопробивные нетканые материалы; регенерированное сырье; методика прогнозирования физико-механических свойств; нейросетевое моделирование; искусственные нейронные сети; прогнозирование свойств; MATLAB

Введение

Нетканые материалы занимают значительное место в текстильной и легкой промышленности благодаря возможности получения полотен с заданным комплексом свойств при высокой производительности технологического процесса. Свойства иглопробивных нетканых материалов зависят от состава волокнистой смеси, поверхностной плотности, толщины полотна, параметров иглопрокалывания и распределения волокон в объеме материала [1; 2]. Неоднородность такой структуры затрудняет построение простых аналитических зависимостей между параметрами производства и физико-механическими свойствами готового полотна.

При разработке нетканых материалов обувного назначения важное значение имеет прогнозирование прочностных и деформационных характеристик, поскольку они определяют эксплуатационные свойства материала. Традиционная оценка этих показателей требует изготовления опытных образцов и проведения лабораторных испытаний, что связано с затратами сырья, времени и производственных ресурсов. Поэтому актуальной задачей является разработка расчетных методов, позволяющих предварительно оценивать свойства материала на этапе выбора состава сырья и структурно-технологических параметров. Возможность такого подхода к прогнозированию показателей качества нетканых полотен на основе ранее полученных экспериментальных и нормативных данных показана в работе [3].

Для моделирования иглопробивных нетканых материалов применяются математические и статистические методы, направленные на прогнозирование и оптимизацию их физико-механических характеристик [4]. Однако при описании свойств полотен, особенно изготовленных из регенерированного сырья, возникают трудности, связанные с нелинейным влиянием технологических факторов, взаимным действием параметров сырья и структуры материала, а также ограниченным объемом экспериментальных данных [5]. В этих условиях использование заранее заданных линейных или полиномиальных зависимостей не всегда позволяет достаточно точно описать формирование свойств материала [6].

Одним из перспективных направлений решения данной задачи является применение методов искусственного интеллекта и нейросетевого моделирования, которые используются для прогнозирования свойств материалов и анализа сложных нелинейных связей в технологических процессах [7; 8]. Для нетканых материалов возможность применения искусственных нейронных сетей при прогнозировании свойств иглопробивных полотен была показана в исследованиях S. Debnath [1; 2]. В дальнейшем нейросетевые и машинные методы получили развитие в задачах прогнозирования прочностных, деформационных и эксплуатационных характеристик текстильных материалов различного строения [3; 6; 9].

Целью работы является разработка и проверка системы нейросетевых моделей для прогнозирования физико-механических свойств иглопробивных нетканых материалов по заданным структурным и технологическим параметрам. Для достижения цели сформирована экспериментальная база данных, определены входные и выходные параметры модели, выполнено нейросетевое прогнозирование разрывной нагрузки и разрывного удлинения, проведена оценка точности прогноза и проверена физико-технологическая адекватность расчетных зависимостей.

1. Входные и выходные параметры для построения нейросетевой модели

Объектом исследования являлись иглопробивные нетканые материалы обувного назначения, изготовленные из регенерированного волокнистого сырья. Поскольку их физико-механические свойства зависят от состава волокнистой смеси, поверхностной плотности, толщины полотна и параметров иглопрокалывания, задача прогнозирования рассматривалась как многофакторная.

Для построения нейросетевой модели была сформирована экспериментальная база данных, включающая структурные и технологические параметры образцов, а также результаты испытаний их физико-механических свойств. Разрывная нагрузка и разрывное удлинение определялись в продольном и поперечном направлениях полотна; по каждому показателю выполнялось по 5 повторных измерений, после чего для моделирования использовались усредненные значения.

Экспериментальная база была представлена в виде массива пар «входные параметры — выходные свойства». Входной вектор имел вид:

$$X = (X_1, X_2, X_3, X_4, X_5, X_6, X_7), \quad (1)$$

где:

X_1 — поверхностная плотность полотна, г/м²;

X_2 — X_4 — содержание трех компонентов в волокнистой смеси, %;

X_5 — толщина полотна, мм;

X_6 — глубина прокалывания, мм;

X_7 — плотность прокалывания, 1/см².

Плотность прокалывания рассматривалась как интегральный технологический параметр, характеризующий интенсивность механического воздействия игл на волокнистый холст. В отличие от отдельных кинематических параметров оборудования, данный показатель позволяет учитывать суммарное воздействие иглопрокалывания на единицу площади полотна. Плотность прокалывания рассчитывалась по формуле:

$$\rho_{игл} = \frac{N_{игл} \cdot f}{B \cdot V \cdot 10^4}, \quad (2)$$

где:

$N_{игл}$ — число игл, участвующих в одном рабочем такте иглопрокалывания, шт;

f — частота ударов игольной плиты, уд/мин;

B — рабочая ширина набивки игольницы, м;

V — скорость движения полотна в зоне иглопрокалывания, м/мин.

Выходной вектор включал четыре физико-механические характеристики:

$$Y = (Y_1, Y_2, Y_3, Y_4), \quad (3)$$

где:

Y_1 — разрывная нагрузка по длине, Н;

Y_2 — разрывная нагрузка по ширине, Н;

Y_3 — разрывное удлинение по длине, мм;

Y_4 — разрывное удлинение по ширине, мм.

Для формирования экспериментальной базы данных были исследованы 16 образцов иглопробивных термоскрепленных нетканых материалов. Волокнистый состав образцов включал: полиэфирное регенерированное волокно 7D × 64 мм (X₂); полиэфирное бикомпонентное волокно 4D × 51 мм (X₃); волокна шерсти из отходов текстильного производства (X₄).

Состав входного вектора нейросетевой модели приведен в таблице 1, выходного вектора — в таблице 2.

Таблица 1

Входной вектор нейросетевой модели

id образца	X ₁ поверхностная плотность полотна, г/м ²	Компоненты волокнутого состава образцов, %			X ₅ средняя номинальная толщина полотна, мм	X ₆ глубина прокалывания, мм	X ₇ плотность прокалывания, см ⁻²
		X ₂	X ₃	X ₄			
1	250	73	27	0	1,75	10	81,00
2	300	85	15	0	2,50	13	72,00
3	300	75	25	0	1,25	13	72,00
4	400	85	15	0	3,50	14	61,71
5	400	75	25	0	3,50	14	61,71
6	450	95	5	0	3,25	14	51,43
7	500	70	30	0	4,00	14	72,00
8	600	75	25	0	4,00	14	60,00
9	650	85	15	0	4,50	15	57,60
10	800	75	25	0	5,00	15	72,00
11	1 200	75	25	0	8,00	16	90,00
12	350	78	7	15	2,50	12	63,00
13	450	10	25	65	1,75	15	51,43
14	650	0	7	93	4,50	16	57,60
15	800	0	20	80	5,00	16	72,00
16	1 200	0	25	75	7,00	18	90,00

Составлено авторами

Таблица 2

Выходной вектор нейросетевой модели

id образца	Разрывная нагрузка, Н		Разрывное удлинение, мм	
	Y ₁ по длине	Y ₂ по ширине	Y ₃ по длине	Y ₄ по ширине
1	136,61	104,72	93,59	110,60
2	215,66	192,86	86,28	108,91
3	269,46	187,20	75,33	96,21
4	416,42	324,52	84,12	97,39
5	456,70	422,60	70,20	91,46
6	458,36	468,98	71,62	95,72
7	629,38	507,56	66,34	85,16
8	635,72	565,94	64,12	81,38
9	761,39	694,26	69,00	92,64
10	1 082,77	898,51	60,03	75,98
11	1 190,51	985,39	54,12	59,34
12	287,43	301,15	106,12	123,16
13	414,08	387,92	101,75	128,62
14	519,64	564,79	112,73	108,73
15	734,33	653,11	88,49	111,58
16	834,23	643,14	86,24	102,22

Составлено авторами

Перед обучением данные были нормализованы, поскольку входные и выходные параметры имеют различную размерность и числовые диапазоны.

Приведение данных к сопоставимому масштабу повышает устойчивость обучения нейронной сети и улучшает сходимость модели [10; 11].

2. Построение нейросетевой модели

Методологический подход к нейросетевому прогнозированию свойств нетканых материалов из регенерированного сырья был рассмотрен авторами в работе [12]. Для прогнозирования физико-механических свойств иглопробивных нетканых материалов использовался многослойный перцептрон. Данный тип нейронной сети применяется для решения задач регрессии и аппроксимации нелинейных зависимостей между входными и выходными параметрами [10, с. 147–152; 11, с. 175–176]. Обучение моделей выполнялось в среде MATLAB с использованием разработанного программного кода [12].

Прогнозирование выполнялось в постановке задачи, при которой по заданному набору структурных и технологических параметров рассчитываются прочностные и деформационные характеристики материала:

$$X \rightarrow Y_{расч}. \quad (4)$$

С учетом малого объема экспериментальной выборки и сравнительно большого числа входных параметров задача была декомпозирована. Вместо одной многовыходной модели построена система одноцелевых нейросетевых моделей: для каждого прогнозируемого показателя формировалась отдельная модель при одинаковом составе входного вектора. В общем виде система моделей может быть представлена следующим образом:

$$f_i(X) \rightarrow Y_i, \quad (5)$$

где:

X — входной вектор структурных и технологических параметров;

Y_i — прогнозируемые физико-механические характеристики материала.

Такой подход позволил снизить сложность обучения каждой отдельной модели и уменьшить риск переобучения при малом количестве экспериментальных образцов. Кроме того, раздельное построение моделей дает возможность оценивать точность прогноза по каждому физико-механическому показателю независимо.

Для получения более устойчивой аппроксимации зависимости между структурно-технологическими параметрами и свойствами материала, а также для снижения вероятности переобучения модели, был применен метод регуляризации.¹

С учетом ограниченного объема экспериментальной базы для оценки устойчивости прогнозирования использовалась схема скользящего контроля по принципу leave-one-out. На каждом шаге один образец исключался из обучающей выборки и использовался для проверки расчетного значения, тогда как остальные образцы применялись для обучения модели. Такая схема позволила использовать максимально возможный объем данных для обучения и одновременно проверить способность модели воспроизводить значения для образцов, не участвовавших в настройке весовых коэффициентов.

Общая схема построения нейросетевой модели включала предварительную обработку данных, формирование системы одноцелевых моделей, обучение нейронных сетей, расчет прогнозных значений и оценку ошибки прогнозирования (рис. 1).

¹ Тихонов А. Н., Арсенин В. Я. Методы решения некорректных задач. М.: Наука, 1986. — 288 с.

Архитектура нейросетевой модели была выбрана и обоснована в ранее выполненной работе авторов [14]. В настоящем исследовании использовалась архитектура 7-10-1, включающая 7 входных параметров, один скрытый слой из 10 нейронов и один выходной параметр. Такая структура применялась для каждой из одноцелевых моделей MLP_1 — MLP_4 .

Выбор нейросетевого подхода обусловлен многофакторным и нелинейным характером зависимости между составом сырья, структурными параметрами полотна, режимами иглопробивания и физико-механическими свойствами материала. Более простые регрессионные модели требуют предварительного задания вида зависимости, например линейной или полиномиальной, что при ограниченном объеме экспериментальных данных может приводить либо к чрезмерному упрощению поведения материала, либо к неустойчивому увеличению числа коэффициентов. В настоящей работе основное внимание уделено проверке нейросетевой модели как расчетного инструмента для прямого прогнозирования свойств; сопоставление с альтернативными регрессионными моделями рассматривается как отдельное направление дальнейшего исследования.



Рисунок 1. Этапы (модули) обучения нейросетевых моделей (разработано авторами)

Качество прогнозирования оценивалось путем сопоставления расчетных и экспериментальных значений по каждому выходному показателю. Для этого определялись абсолютные и относительные ошибки прогноза, а также анализировалось соответствие общей тенденции изменения расчетных и экспериментальных значений.

Такой подход позволяет оценить пригодность построенной системы моделей для предварительного прогнозирования свойств материала при заданных структурных и технологических параметрах.

3. Результаты нейросетевого прогнозирования

На основе сформированной экспериментальной базы данных была выполнена проверка работы системы нейросетевых моделей, предназначенных для прогнозирования физико-механических свойств иглопробивных нетканых материалов. Для каждого образца в нейросетевую модель вводился набор структурных и технологических параметров, после чего рассчитывались значения разрывной нагрузки и разрывного удлинения в продольном и поперечном направлениях.

Полученные расчетные значения сопоставлялись с экспериментальными результатами испытаний (табл. 3).

Результаты сопоставления экспериментальных и расчетных значений представлены на рисунке 2. Для моделей MLP₁ и MLP₂, прогнозирующих разрывную нагрузку по длине и ширине, наблюдается близкое совпадение расчетных и экспериментальных данных по всему диапазону исследуемых образцов. Это указывает на то, что прочностные характеристики достаточно устойчиво описываются выбранным набором входных структурно-технологических параметров.

Таблица 3

Нормализованные экспериментальные данные
и расчетные значения нейросетевых моделей MLP₁ — MLP₄

id образ ца	Разрывная нагрузка				Разрывное удлинение			
	по длине		по ширине		по длине		по ширине	
	Y ₁ эксп	Y ₁ расч — MLP ₁	Y ₂ эксп	Y ₂ расч — MLP ₂	Y ₃ эксп	Y ₃ расч — MLP ₃	Y ₄ эксп	Y ₄ расч — MLP ₄
P1	0	$3 \cdot 10^{-07}$	0	-0,0063	0,6734	0,6774	0,7449	0,7406
P2	0,075	0,0750	0,1001	0,1206	0,5487	0,5558	0,7144	0,7067
P3	0,1261	0,1261	0,0937	0,0977	0,3619	0,3996	0,4851	0,5035
P4	0,2655	0,2655	0,2496	0,2931	0,5119	0,3949	0,5064	0,5323
P5	0,3037	0,3037	0,361	0,3277	0,2744	0,2855	0,3994	0,3759
P6	0,3053	0,3053	0,4136	0,4045	0,2986	0,4227	0,4763	0,5095
P7	0,4676	0,4676	0,4574	0,4564	0,2085	0,2325	0,2856	0,2760
P8	0,4736	0,4736	0,5237	0,5716	0,1706	0,1848	0,2174	0,2467
P9	0,5928	0,5928	0,6694	0,6501	0,2539	0,2005	0,4207	0,3708
P10	0,8978	0,8978	0,9013	0,8676	0,1008	0,1065	0,1199	0,1287
P11	1	1,0000	1	1,0040	0	0,0088	0	0,0030
P12	0,1431	0,1431	0,223	0,2012	0,8872	0,8140	0,9717	0,9468
P13	0,2633	0,2633	0,3216	0,3145	0,8127	0,8017	0,9258	0,9178
P14	0,3634	0,3634	0,5224	0,5233	1	1,0272	1	1,0015
P15	0,5672	0,5672	0,6227	0,6348	0,8935	0,8741	0,9612	0,9744
P16	0,6619	0,6619	0,6114	0,6105	0,548	0,5553	0,5936	0,5861

Составлено авторами

Для моделей MLP₃ и MLP₄, прогнозирующих разрывное удлинение по длине и ширине (рис. 3), совпадение расчетных и экспериментальных значений также сохраняется, однако для отдельных образцов замечен больший разброс. Это связано с тем, что деформационные характеристики в большей степени зависят от локальной неоднородности волокнистой структуры, характера перераспределения волокон при растяжении и особенностей разрушения конкретной пробы.




Рисунок 2. Экспериментальные значения разрывной нагрузки по длине (а) и по ширине (б) и расчетные данные нейросетевых моделей MLP1 и MLP2 (составлено авторами)




Рисунок 3. Экспериментальные значения разрывного удлинения по длине (а) и по ширине (б) и расчетные данные нейросетевых моделей MLP3 и MLP4 (составлено авторами)

Для количественной оценки точности прогнозирования были рассчитаны следующие метрики по каждому выходному показателю [15, с. 55]: среднеквадратичная ошибка (MSE), корень из среднеквадратичной ошибки (RMSE), средняя абсолютная ошибка (MAE), коэффициент корреляции (R), коэффициент детерминации (R^2). Средние значения метрик приведены в таблице 4.

Таблица 4

Средние метрики точности нейросетевого прогнозирования в нормированной шкале

id нейросетевой модели	Выходной параметр y_i	MSE	RMSE	MAE	R	R^2
MLP1	Y1 — разрывная нагрузка по длине	0,000131	0,011463	0,008839	0,999263	0,998518
MLP2	Y2 — разрывная нагрузка по ширине	0,000503	0,022433	0,016586	0,996638	0,993229
MLP3	Y3 — разрывное удлинение по длине	0,002567	0,050666	0,034074	0,985851	0,971642
MLP4	Y4 — разрывное удлинение по ширине	0,000449	0,021187	0,016784	0,997589	0,995136

Составлено авторами

По данным таблицы 4, все четыре модели обеспечивают высокий уровень согласования расчетных и экспериментальных значений. Коэффициент детерминации находится в диапазоне от $R^2 = 0,971642$ для модели MLP3 до $R^2 = 0,998518$ для модели MLP1.

Наименьшая средняя абсолютная ошибка в нормированной шкале получена для разрывной нагрузки по длине, наибольшая — для разрывного удлинения по длине. Это указывает на то, что наиболее устойчиво модель описывает прочностные показатели, тогда как деформационные характеристики являются более сложными для прогнозирования.

Поскольку обучение нейросетевых моделей выполнялось на нормализованных данных, значения MAE в таблице 4 выражены в безразмерной шкале. Для практической интерпретации точности прогноза средняя абсолютная ошибка была переведена в физические единицы измерения: для разрывной нагрузки — в Н, для разрывного удлинения — в мм. Обратный перевод выполнялся с учетом диапазона изменения соответствующего выходного параметра в экспериментальной выборке (табл. 5).

Таблица 5

**Перевод средней абсолютной ошибки
нейросетевого прогнозирования в физические единицы измерения**

Нейросетевая модель	Выходной параметр	MAE норм	Диапазон изменения Y	MAE в физических единицах
MLP1	Y1 — разрывная нагрузка по длине	0,008839	1 053,90 Н	9,32 Н
MLP2	Y2 — разрывная нагрузка по ширине	0,016586	880,67 Н	14,60 Н
MLP3	Y3 — разрывное удлинение по длине	0,034074	58,61 мм	2,00 мм
MLP4	Y4 — разрывное удлинение по ширине	0,016784	69,28 мм	1,16 мм

Составлено авторами

Как видно из таблицы 5, средняя абсолютная ошибка прогнозирования составляет 9,32 Н для разрывной нагрузки по длине, 14,60 Н для разрывной нагрузки по ширине, 2,00 мм для разрывного удлинения по длине и 1,16 мм для разрывного удлинения по ширине.

Для оценки практической значимости полученной точности ошибка нейросетевого прогнозирования была сопоставлена с экспериментальной вариативностью Δ , определенной по результатам повторных испытаний образцов (табл. 6).

Таблица 6

**Сопоставление экспериментальной
вариативности и ошибки нейросетевого прогнозирования**

Показатель	Абсолютная ошибка выборки Δ	MAE нейросетевой модели	Характер сопоставления
Разрывная нагрузка по длине	7,24–153,73 Н	9,32 Н	на уровне нижней границы экспериментальной ошибки
Разрывная нагрузка по ширине	8,10–127,43 Н	14,60 Н	сопоставима с экспериментальной ошибкой
Разрывное удлинение по длине	5,39–28,83 мм	2,00 мм	ниже экспериментальной ошибки
Разрывное удлинение по ширине	8,96–39,55 мм	1,16 мм	ниже разброса ошибки эксперимента

Составлено авторами

Сопоставление показывает, что ошибка нейросетевого прогнозирования находится на уровне или ниже экспериментальной ошибки выборки.

Следовательно, расхождение между расчетными и экспериментальными значениями не превышает характерную неопределенность, связанную с испытанием неоднородного иглопробивного материала.

Это подтверждает пригодность построенной системы моделей для предварительного прогнозирования физико-механических свойств в пределах исследованного диапазона параметров.

4. Проверка физико-технологической адекватности нейросетевой модели

Для проверки того, что обученная нейросетевая модель не только воспроизводит экспериментальные данные, но и дает физически объяснимые расчетные зависимости, был проведен вычислительный эксперимент. В ходе этого эксперимента отдельные входные параметры варьировались в пределах диапазона экспериментальной базы, а остальные параметры фиксировались на уровне средних значений соответствующих входных признаков в экспериментальной выборке (рис. 4).

На рисунке 4 а показана расчетная поверхность зависимости разрывной нагрузки по длине от поверхностной плотности и толщины полотна. Анализ поверхности показывает, что увеличение поверхностной плотности и толщины сопровождается ростом разрывной нагрузки, однако эта зависимость не является линейной. При увеличении поверхностной плотности прирост прочности изменяется неравномерно, что свидетельствует о совместном влиянии массы волокнистого слоя и объемной структуры полотна.




Рисунок 1. Влияние на разрывную нагрузку по длине (а) поверхностной плотности и толщины полотна; (б) параметров иглопрокалывания (составлено авторами)

На рисунке 4 б представлена расчетная зависимость разрывной нагрузки по длине от глубины прокалывания и плотности прокалывания. Форма поверхности показывает, что параметры иглопрокалывания оказывают сложное нелинейное влияние на прочность. В определенной области увеличение интенсивности иглопрокалывания способствует росту прочности за счет усиления межволоконных связей, однако дальнейшее увеличение механического воздействия не приводит к пропорциональному приросту прочности. Это может быть связано с тем, что избыточное иглопрокалывание не только уплотняет структуру, но и изменяет характер распределения и закрепления волокон.

Дополнительно был выполнен анализ численных производных разрывной нагрузки по поверхностной плотности полотна. При расчете производных варьировалась только поверхностная плотность, а остальные входные параметры фиксировались на уровне средних значений по экспериментальной выборке: волокнистый состав, толщина полотна, глубина прокола иглами и плотность проколов. Такой подход позволил оценить чувствительность прогнозируемой разрывной нагрузки к изменению поверхностной плотности при неизменных средних значениях остальных структурно-технологических факторов (рис. 5).

Как видно из рисунка 5, производные разрывной нагрузки по длине и ширине остаются положительными во всем рассматриваемом диапазоне поверхностной плотности. Следовательно, увеличение поверхностной плотности сопровождается ростом прочности как в продольном, так и в поперечном направлении.

При этом производные имеют максимум в средней части диапазона поверхностной плотности. Это означает, что существует область, в которой увеличение массы волокнистого слоя дает наибольший прирост прочности. После прохождения этой области прочность продолжает возрастать, но менее интенсивно. Такой результат важен с технологической точки зрения, поскольку показывает, что увеличение поверхностной плотности выше определенного уровня может быть менее эффективным с позиции прироста прочностных характеристик.




Рисунок 2. Анализ производных разрывной нагрузки (по длине — синяя линия и по ширине — красная линия) при изменении поверхностной плотности (составлено авторами)

Проведенный вычислительный эксперимент показал, что обученные нейросетевые модели дают физико-технологически согласованное поведение в пределах исследованного диапазона параметров. Модели воспроизводят нелинейный характер влияния поверхностной плотности, толщины и параметров иглопробивания на прочность материала и не формируют резких, физически необъяснимых скачков прогнозируемых значений. Это подтверждает возможность использования моделей не только для численного прогноза отдельных значений, но и для анализа влияния структурно-технологических факторов на свойства иглопробивного полотна.

Следует отметить, что полученные расчетные зависимости следует рассматривать как интерполяционные, то есть применимые в пределах диапазонов входных параметров, представленных в экспериментальной базе. Использование моделей для расчета свойств материалов с поверхностной плотностью, волокнистым составом, толщиной полотна или параметрами иглопробивания, выходящими за пределы исследованной области, требует дополнительной экспериментальной проверки и расширения обучающей выборки. Это ограничение связано с тем, что нейросетевая модель воспроизводит зависимости, сформированные на основе имеющегося массива экспериментальных данных, и не должна использоваться для необоснованной экстраполяции.

Заключение

В работе решена задача нейросетевого прогнозирования физико-механических свойств иглопробивных термоскрепленных нетканых материалов обувного назначения из регенерированного волокнистого сырья. Для расчета разрывной нагрузки и разрывного удлинения в продольном и поперечном направлениях построена система из четырех одноцелевых нейросетевых моделей с общим входным вектором, включающим поверхностную плотность, волокнистый состав, толщину полотна и параметры иглопрокалывания.

Полученные результаты показали высокое согласование расчетных и экспериментальных данных: коэффициент детерминации для построенных моделей составил от $R^2 = 0,971642$ до $R^2 = 0,998518$. После денормализации средняя абсолютная ошибка прогноза находилась в пределах экспериментального разброса, что подтверждает пригодность разработанной системы моделей для предварительной оценки свойств материалов в исследованном диапазоне параметров.

Вычислительный эксперимент показал физико-технологическую согласованность полученных зависимостей: модель воспроизводит нелинейное влияние поверхностной плотности, толщины полотна и параметров иглопрокалывания на разрывную нагрузку. Анализ производных позволил выделить область, в которой увеличение поверхностной плотности дает наибольший прирост прочности.

Разработанная система нейросетевого прогнозирования может использоваться как расчетный инструмент при проектировании иглопробивных нетканых материалов, выборе рациональных структурно-технологических параметров и сокращении числа пробных выработок в пределах исследованной области входных данных. Применение модели за пределами этих диапазонов следует рассматривать как экстраполяцию, требующую дополнительной экспериментальной проверки и расширения обучающей базы. Дальнейшее развитие исследования связано с расширением экспериментальной базы, проверкой модели на независимых образцах и сопоставлением точности нейросетевого подхода с альтернативными регрессионными методами.

ЛИТЕРАТУРА

1. Debnath, S. Studies on compression properties of polyester needle-punched nonwoven fabrics under dry and wet conditions / S. Debnath, M. Madhusoothanan // Journal of Industrial Textiles. — 2012. — Vol. 41, № 4. — P. 292–308. — DOI 10.1177/1528083711416394.
2. Debnath, S. Modelling of Needle-Punched Nonwoven Fabric Properties Using Artificial Neural Network / S. Debnath // Artificial Neural Networks — Industrial and Control Engineering Applications / ed. by K. Suzuki. — Rijeka: InTech, 2011. — P. 65–88. — ISBN 978-953-307-220-3. — DOI 10.5772/16123.
3. Прогнозирование нормативных значений показателей качества нетканых геотекстильных полотен / М. А. Лысова, Н. А. Грузинцева, Т. О. Гойс, Б. Н. Гусев // Известия высших учебных заведений. Технология текстильной промышленности. — 2022. — № 4(400). — С. 47–51. — DOI 10.47367/0021-3497_2022_4_47. — EDN TIENPD.
4. Бурибаева, И. Н. Исследование и моделирование технологии производства иглопробивных нетканых материалов с целью прогнозирования и оптимизации их физико-механических характеристик / И. Н. Бурибаева, В. Г. Митихин, А. П. Сергеев // Текстильная промышленность. — 2006. — № 8. — С. 17-21. — EDN HUBNFD. <https://elibrary.ru/item.asp?id=9233565>.
5. Chauhan, N. Applications of Artificial Neural Network in Textiles / N. Chauhan, N. Yadav, N. Arya // International Journal of Current Microbiology and Applied Sciences. — 2018. — Vol. 7, № 4. — P. 3134–3143. — DOI 10.20546/ijcmas.2018.704.356.
6. Rawal, A. Predicting the Properties of Needle punched Nonwovens Using Artificial Neural Network / A. Rawal, A. Majumdar, S.C. Anand, T. Shah // Journal of Applied Polymer Science. — 2009. — Vol. 112. — P. 3575–3581. — DOI 10.1002/app.29687.

7. Tu, Y.-F. A Systematic Review of AI-Driven Prediction of Fabric Properties and Handfeel / Y.-F. Tu, M.-Y. Kwan, K.-L. Yick // *Materials*. — 2024. — Vol. 17, № 20. — Art. 5009. — DOI 10.3390/ma17205009.
8. Elkateb, S. Prediction of Mechanical Properties of Woven Fabrics by ANN / S.N. Elkateb // *Fibres & Textiles in Eastern Europe*. — 2022. — Vol. 30, № 4. — P. 54–59. — DOI 10.2478/ftce-2022-0036.
9. Antweiler, D. Graph-based tensile strength approximation of random nonwoven materials by interpretable regression / D. Antweiler, M. Harmening, N. Marheineke, A. Schmeißer, R. Wegener, P. Welke // *Machine Learning with Applications*. — 2022. — Vol. 8. — Art. 100288. — DOI 10.1016/j.mlwa.2022.100288.
10. Haykin, S. *Neural Networks and Learning Machines* / S. Haykin. — 3rd ed. — Hamilton: Pearson Education, 2009. — 937 p. — ISBN 978-0-13-147139-9.
11. Bishop, C.M. *Pattern Recognition and Machine Learning* / C.M. Bishop. — New York: Springer, 2006. — 738 p. — ISBN 978-0-387-31073-2.
12. Свидетельство о государственной регистрации программы для ЭВМ «Neurofelt v1.0», № 2026683144, 29.07.2026. Заявка № 2026680605/69 от 12.06.2026. Орлов А. В., Шустов Ю. С., Орлова И. А.
13. Орлов, А. В. Методологические основы нейросетевого прогнозирования свойств нетканых материалов из регенерированного сырья / А. В. Орлов // *Безопасность. Управление. Искусственный интеллект*. — 2026. — Т. 2, № S2. — С. 56–66. — EDN YUOBXS.
14. Орлов, А. В. Выбор архитектуры нейронной сети для прогнозирования свойств нетканых материалов / А. В. Орлов, Ю. С. Шустов, Е. А. Кирсанова, И. А. Орлова // *Дизайн и технологии*. — 2026. — № 112(2).
15. Веревкин, А. П. Искусственный интеллект в задачах моделирования, управления, диагностики технологических процессов: монография / А. П. Веревкин, Т. М. Муртазин. — Москва; Вологда: Инфра-Инженерия, 2023. — 232 с.

Orlov Alexander Vasilievitch

Russian State University named A.N. Kosygin (Technologies. Design. Art), Moscow, Russia

E-mail: metroid.prime@yandex.ru

RSCI: https://elibrary.ru/author_profile.asp?id=1157673

Shustov Yuriy Stepanovitch

Russian State University named A.N. Kosygin (Technologies. Design. Art), Moscow, Russia

E-mail: 6145263@mail.ru

RSCI: https://elibrary.ru/author_profile.asp?id=484967

Prediction of physical and mechanical properties of needle-punched nonwoven materials based on neural network modeling

Abstract. The article presents the results of a study aimed at developing a neural network-based system for predicting the physical and mechanical properties of needle-punched thermally bonded nonwoven materials for footwear applications made from regenerated fibrous raw materials. The relevance of the work is associated with the need for preliminary assessment of the breaking load and elongation at break of nonwoven fabrics at the stage of selecting the fiber composition and structural and technological parameters, since carrying out a full range of pilot production runs and laboratory tests requires significant time and material costs. The purpose of the study was to construct and verify neural network models that make it possible to calculate the physical and mechanical properties of the material based on specified parameters of the raw material, fabric structure, and needle-punching process. The practical implementation of prediction was carried out in the MATLAB software environment using the Deep Learning Toolbox module. The authors formed an experimental database based on 16 samples of needle-punched nonwoven materials. Surface density, fiber composition, fabric thickness, needle penetration depth, and punch density were used as input parameters. Breaking load and elongation at break in the longitudinal and transverse directions were considered as output parameters. A separate neural network model was constructed for each output parameter. The authors assessed the prediction accuracy and compared the model error with experimental variability. A high agreement between calculated and experimental data was established. It is shown that the developed neural network-based prediction system can be used as a calculation tool in the preliminary design of needle-punched nonwoven materials and in the selection of rational structural and technological parameters.

Keywords: needle-punched nonwoven materials; regenerated raw materials; method for predicting physical and mechanical properties; neural network modeling; artificial neural networks; property prediction; MATLAB