

**Норкин Владимир Сергеевич**

магистрант

**Тихомиров Сергей Германович**

д-р техн. наук, профессор

ФГБОУ ВО «Воронежский государственный

университет инженерных технологий»

г. Воронеж, Воронежская область

DOI 10.21661/r-461591

## **ПРОГНОЗИРОВАНИЕ СВОЙСТВ ПОЛИМЕРНЫХ КОМПОЗИЦИЙ**

### **НА БАЗЕ МЕТОДОВ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА**

*Аннотация:* в статье рассматривается метод прогнозирования свойств полимерных композиций (ПК), а именно прогнозирование при построении и обучении искусственной нейронной сети (ИНС). С учетом сложных внутренних связей объекта возникает проблема прогнозирования различных параметров и показателей. Целью работы является обеспечение выбора оптимальных дозировок мягчителей в составе полимерной композиции, которые обеспечили бы заданные ФМП. В ходе исследования происходит статистический анализ исходных данных, в качестве которых выступают рецепты смесей полимерных композиций на основе каучука СКС-30 АРК. В основе построения ИНС лежит регрессионный анализ. Представлены результаты прогнозирования и проведена оценка результатов в виде графика и таблиц.

*Ключевые слова:* полимерные композиции, искусственные нейронные сети, нормализация данных, прогнозирование, описательная статистика, регрессионный анализ.

В настоящее время можно заметить, что вектор развития смещается от обычного совершенствования производственных функций и возможностей оборудования в сторону разработки специализированного программного обеспечения, которое в свою очередь позволяет повысить коэффициент полезного дей-

ствия любого агрегата без изменения его физических свойств за счет более точной и проработанной обратной связи между компонентами производственного процесса.

Анализ существующих прогнозируемых систем говорит о том, что существует реальная научно-техническая проблема создания комплексных систем прогнозирования, построенных на универсальных принципах, обеспечивающих высокий уровень достоверности прогнозирования физико-механических показателей конечного продукта.

Отсутствие оперативных методов оценки свойств полимерных композиций при их производстве обуславливает применение современных подходов. Для решения задач прогнозирования необходимо сформировать базу данных с множеством состояний объекта и произвести статистический анализ каждого компонента полимерных композиций из репрезентативного набора экспериментальных данных. Вторая задача связана с созданием надежной интеллектуальной системы принятия решений.

Работа реализована с использованием аппарата искусственных нейронных сетей (ИНС) и направления «кибернетика черного ящика» [2].

Статистический анализ данных проведен в таблице 1 при помощи описательных статистик.

Таблица 1

*Описательная статистика исходных данных*

	$x1$ (масло И-12)	$x2$ (масло ПН-6)	$x3$ (ПБН)	$x4$ Mhp	$y1$ ( $\varepsilon$ , %)	$y2$ ( $f_p$ , $Mpa$ )	$y3$ (НА, усл. ед.)
n	16	16	16	16	16	16	16
mean	2,981	2,981	2,981	71,183	297,188	13,381	79,875
sd	2,292	2,292	2,292	13,976	52,63	2,361	5,702
95% CI	1,76–4,203	1,76–4,203	1,76–4,20	63,73–78,63	269,1–325,2	12,12–14,64	76,86–82,91
min	0,3	0,3	0,3	57,394	195	9,7	73
max	8,3	8,3	8,3	108,38	380	16,6	93
median	2,35	2,35	2,35	67,259	305	13,9	78
iqr	3,025	3,025	3,025	16,664	65	3,3	7,75

Описание данных является начальным этапом в их количественном анализе и первым шагом к использованию других статистических процедур [3].

Исходными данными является набор дозировок модификаторов (индустриальное масло И-12 ( $X_1$  м.ч. %), масло ПН-6 ( $X_2$  м.ч. %), ПБН ( $X_3$  м.ч. %)), входящих в полимерные композиции и их физико-механические показатели резиновых вулканизатов, полученных на их основе (ФМП):

- вязкость по Муни;
- условная прочность при растяжении ( $f_p$ , Мпа);
- относительное удлинение при разрыве ( $\epsilon_p$ , %);
- твердость по Шору А ( $H_A$ , усл. ед.).

Поиск оптимальной модели прогнозирования осуществлялся по следующему алгоритму:

1. Нормализация данных и деление их на подвыборки.
2. Выбор топологии сети.
3. Экспериментальный подбор параметров обучения.
4. Обучение.
5. Расчет и сравнения оценок точности моделей прогнозирования.

Для ускорения обучения, уменьшения погрешностей при решении задачи используется процедура нормирования [1]. Исследуемый объект характеризуется входными сигналами  $x_i^j$  и выходными сигналами  $y_m^j$ . Тогда процедуру нормирования определяются следующими соотношениями:

$$\tilde{x}_i^j = \frac{x_i^j - \bar{x}_i}{\sigma_{x_i}}, \quad \tilde{y}_m^j = \frac{y_m^j - \bar{y}_m}{\sigma_{y_m}},$$

где средние значения  $\bar{x}_i$ ,  $\bar{y}_m$ ,  $\sigma_{x_i}$ ,  $\sigma_{y_m}$  – стандартные отклонения.

После такого преобразования средние значения  $\tilde{x}_i = \tilde{y}_m = 0$ , а стандартные отклонения  $\sigma_{\tilde{x}_i} = \sigma_{\tilde{y}_m} = 1$ . Вводя интервал изменения входного сигнала  $\tilde{x}_i^j$

$\Delta \tilde{x}_i = \max(\tilde{x}_i^j) - \min(\tilde{x}_i^j)$ , и интервал варьирования масштабированной переменной:

$$\Delta \hat{x}_i = \max(\hat{x}_i^j) - \min(\hat{x}_i^j),$$

а также масштабирующий параметр:

$$\Delta x_i = \frac{\Delta \hat{x}_i}{\Delta \tilde{x}_i} = \frac{\max(\hat{x}_i^j) - \min(\hat{x}_i^j)}{\max(\tilde{x}_i^j) - \min(\tilde{x}_i^j)},$$

преобразование для входных сигналов принимает вид:

$$\hat{x}_i^j = \Delta x_i \cdot \tilde{x}_i^j + (\min(\hat{x}_i^j) - \Delta x_i \cdot \min(\tilde{x}_i^j)),$$

где  $i = 1, 2, \dots, k_1$  – номер входа,  $m = 1, 2, \dots, k_N$  – номер выхода, а  $j = 1, 2, \dots, p$  – номер образа из обучающей выборки.

Применение масштабированных значений  $\hat{x}_i^j, \hat{y}_m^j$  в качестве обучающих пар позволило ускорить обучение сети и избежать работы нейронов в режиме насыщения. В таблице 2 представлен фрагмент результатов масштабирования исходных данных на интервале  $[0,1]$ .

Таблица 2

*Исходные данные до и после процедуры нормализации.*

Вид данных/ параметр	x1	x2	x3	x4	y1	y2	y3
Исходные	1.3	1.3	1.3	58.094	340	16.0	75
Нормализо- ванные	0.05	0.05	0.05	0.059	0.066	0.75	0.19

Множество данных, описывающих исследуемый объект, было разбито на три подмножества. Множество  $L$  (70%) используется непосредственно для обучения. Множество  $V$  (15%) – для проверки степени обучения сети на различных итерациях. Множество  $T$  (15%) – для оценки качества работы сети по окончании обучения, при этом оно не пересекается с обучающей выборкой L. В работе использован алгоритм обучения многослойных нейронных сетей методом обратного распространения ошибки.

При обучении многослойного персептрона методом обратного распространения ошибки, имеется совокупность векторов входных и желаемых выходных сигналов:  $\{X^1, X^2, \dots, X^p\}$  и  $\{D^1, D^2, \dots, D^p\}$  соответственно, где  $p$  – количество элементов в обучающем множестве. Подав произвольный вектор  $X^q$  на входы сети, на ее выходе получаем некоторый вектор  $Y^{(N)q}$ .

Результаты прогнозирования ФМП при использование ИНС представлены в таблице 3 и в графике сравнения (рис. 1).

Таблица 3

*Результаты прогнозирования ФМП*

<i>Вид выборки</i>	<i>εр, %</i> <i>Фактическое</i>	<i>εр, %</i> <i>Модели ИНС</i>	<i>Абс. ошиб. %</i>	<i>Точн. прогн. %</i>
Обучающая	310,0000	343,9933	10,96559	89,03441
Обучающая	325,0000	328,9534	1,216443	98,78356
Контрольная	340,0000	308,3350	9,313223	90,68678
Обучающая	265,0000	252,9095	4,562445	95,43756
Обучающая	300,0000	339,9511	13,31702	86,68298
Тестовая	320,0000	318,5876	0,441384	99,55862
Тестовая	280,0000	289,5580	3,413564	96,58644

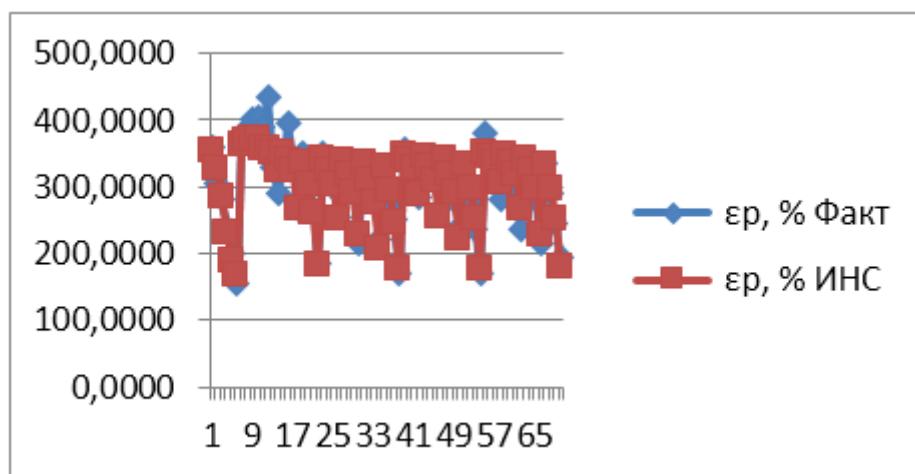


Рис 2. График сравнения исходных данных, полученных на опытным путем, и данных, полученных при помощи модели ИНС

После процедуры обучения ИНС осуществлена оценка качества результатов прогнозирования (таблица 4). Средняя относительная ошибка по всем значениям не превышает 5,5%.

Таблица 4

*Оценки точности прогнозирования*

<i>Средняя относительная ошибка, %</i>	<i>ep</i>	<i>fp,Mna</i>	<i>HA, усл.ед.</i>
$MAPE = \frac{1}{N} \sum_{t=1}^N \frac{ Z(t) - \hat{Z}(t) }{Z(t)} \cdot 100\%$	5,3745	5,4533	2,0674
<i>Средняя абсолютная ошибка</i>			
$MAE = \frac{1}{N} \sum_{t=1}^N  Z(t) - \hat{Z}(t) $	16,3325	0,7111	1,6292
<i>Среднеквадратичная ошибка</i>			
$MSE = \frac{1}{N} \sum_{t=1}^N (Z(t) - \hat{Z}(t))^2$	459,6753	0,8515	4,088

Таким образом, созданная модель прогнозирования физико-механических показателей полимерных композиций, позволяет получать изделия с прогнозируемыми свойствами, а также корректировать состав композиций в зависимости от предъявляемых требований. Разработанная методика может быть использована для прогнозирования ФМП в процессе производства полимерных композиций.

**Список литературы**

1. Матвеев М.Г. Модели и методы искусственного интеллекта. Применение в экономике: Учебное пособие / М.Г. Матвеев, А.С. Свиридов, Н.А. Алейников, 2008. – С. 221–223.
2. Кацуба Ю.Н. Применение искусственных нейронных сетей для диагностирования изделий / Ю.Н. Кацуба, И.В. Власова // Международный научно-исследовательский журнал. – 2005. – №3 (34). – Ч. 1. – С. 68–70.
3. Строителев В.Н. Статистические методы – основной инструмент специалиста в области качества // Качество, инновации, образование. – 2002. – №1. – С. 11–17.