

Рисунок 1. Композиционный материал алюминий-углеродные нановолокна

В качестве методики компактирования материала была выбрана методика горячего прессования. С помощью данной методики была произведена серия опытов в диапазоне давлений от 2 до 5 ГПа, температуры от 400 до 1500 °С и времени выдержки от 15 до 60 секунд.

Результаты исследований показали, что при добавлении уже 1 масс. % УНВ наблюдается рост твердости по сравнению с чистым алюминием с 30 до 60 НВ, а также падение теплопроводности с 237 до 60 Вт/(м\*К). Резкий рост твердости полученного композита объясняется природой УНВ и их высокими прочностными свойствами. Резкое снижение теплопроводности объясняется тем, что каждая частица алюминия эффективно отделяется от остальных частиц слоем из хаотически направленных УНВ с низкой теплопроводностью.

Работа поддержана грантом РФФИ №16-32-80092.

#### **СПИСОК ЦИТИРОВАННЫХ ИСТОЧНИКОВ**

1. Т.С. Кольцова, Ф.М. Шахов, А.А. Возняковский, А.И. Рудской, А.Г. Насибулин, О.В. Толочко. Получение компактного материала алюминий – углеродные нановолокна с высокими механическими свойствами методом горячего прессования. ЖТФ. 84(11) (2014) 47-51.

УДК 620.004.5

### **ИСПОЛЬЗОВАНИЕ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ ПРИ АКУСТИЧЕСКОЙ ДИАГНОСТИКЕ МНОГОВАЛЬНЫХ ЗУБЧАТЫХ ПРИВОДОВ**

*Драган А.В., Парфиевич А.Н., Саливончик Ю.Н.*

Брестский государственный технический университет

Брест, Республика Беларусь.

Искусственная нейронная сеть (ИНС) является математической, либо программной, либо аппаратной моделью, моделирующая принципы организации и функционирования биологических нейронных сетей, и состоит из соединенных и взаимодействующих между собой вычислительных элементов – нейронов.

Теория ИНС имеет цель моделирования биологической нейронной сети для достижения таких свойств систем как способность к обучению, самоорганизации и адаптации. На сегодняшний день существует большое количество архитектур ИНС, которые благодаря своим особенностям, например, в процессе обучения выявлять сложные зависимости в наборе данных, с успехом применяют при решении таких сложных инженерных задач как распознавание образов, классификация, прогнозирование и т.д. В ходе проводимых исследований производилась попытка применения ИНС в целях диагностики зубчатых приводов.

Одним из объектов исследования был выбран горизонтальный редуктор с цилиндрическими прямозубыми колесами. В качестве источника информации о его состоянии использовался акустический шум, сформированный аппаратно-программным комплексом [1] на основе данных, полученных с измерительного микрофона с капсулем M101. Также одновременное применение преобразователей угловых перемещений на входном и выходном валах объекта дало возможность с высокой точностью определять частоты вращения входного и выходного вала и частоты характерных составляющих на спектре анализируемого сигнала. На одном из колес редуктора моделировались эксплуатационные дефекты в виде скола зуба. Замеры проводились для каждого состояния (25%, 50%, 75% длины зуба и без зуба) в количестве 25 раз для накопления необходимого объема данных. Результаты, полученные при использовании серийных колес, приняты за эталонные.

Анализируя полученные спектры акустического сигнала, можно выявить в области низких частот оборотные  $f_0$  и кратные им составляющие всех валов кинематической цепи редуктора, в области пересопряжения зубьев – зубцовые  $f_z$  и кратные им составляющие зубчатых колес, а также составляющие колебаний с комбинированными частотами  $|f_z \pm n f_0|$  ( $1, n=0,5; 1; 1,5; 2$  и т.д.) (рисунок 1, а). Процедура выявления этих компонентов из чрезмерно насыщенного сигнала очень трудоемка, что привело к разработке и реализации в программной части комплекса новой функции, позволяющей автоматически получать значения всех составляющих, формирующих диагностические признаки (рисунок 1, б).

Полученный объем экспериментальных данных был разбит на 5 классов в зависимости от состояния зуба и применен при решении задачи классификации. В качестве классификатора была выбрана многослойная нейронная сеть с одним скрытым слоем, состоящим из нейронов Кохонена [2]. Ее структура представлена в виде трех слоев:

- первый слой нейронных элементов предназначен для распределения входных сигналов на нейроны Кохонена скрытого слоя. Размерность входного слоя определяется размерностью анализируемых данных. В нашем случае используются данные размерностью равной 60, следовательно, количество нейронов распределительного слоя равно 60. Входными сигналами являются параметры, сформированные на основе функции аппаратно-программного комплекса «Анализ гармоник» (рис. 1, б).

- второй, скрытый, слой искусственной нейронной сети состоит из нейронов Кохонена. Слой Кохонена играет ключевую роль в классификации данных и осуществляет кластеризацию входного пространства образов, в результате чего образуются кластеры различных образов, каждому из которых соответствует свой нейронный элемент.

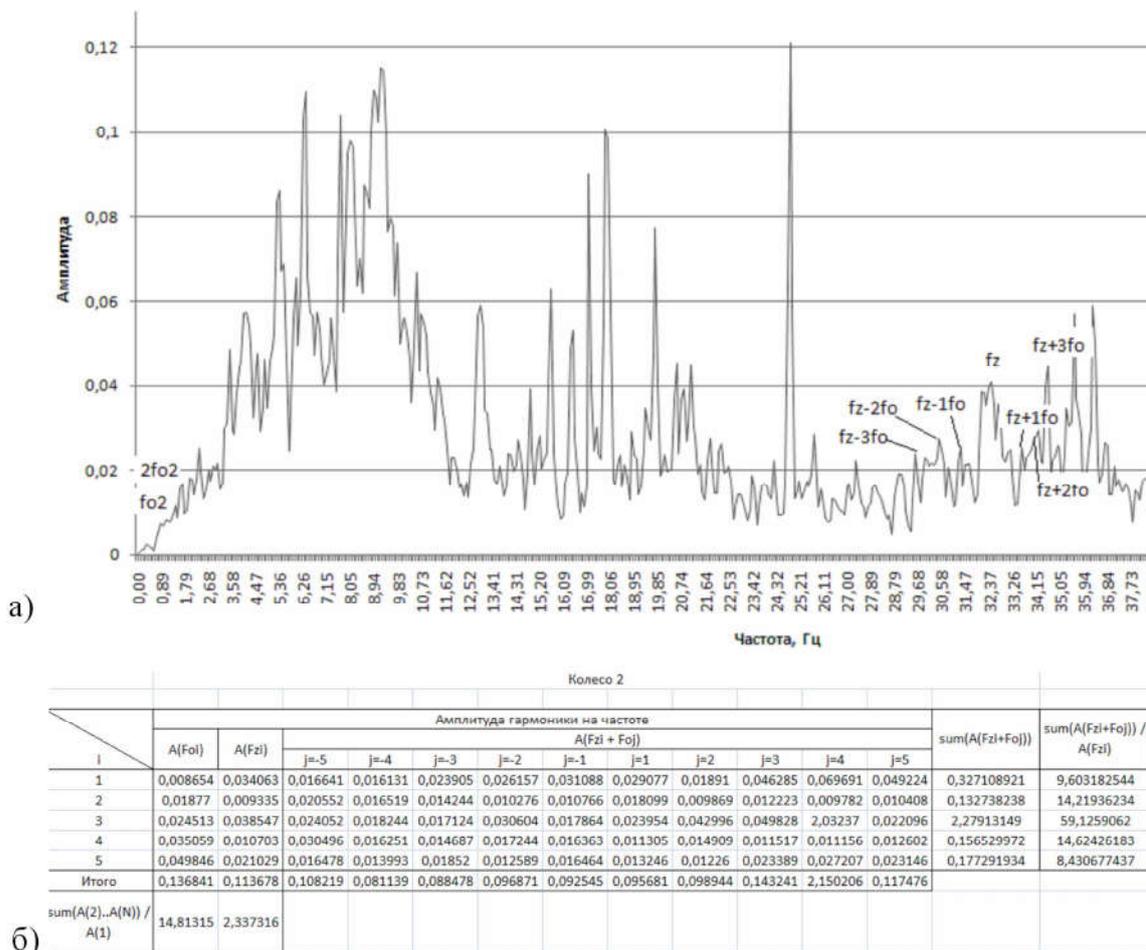


Рисунок 1 - Результат обработки спектра акустического сигнала с помощью функции аппаратно-программного комплекса «Анализ гармоник»: а) фрагмент спектра акустического сигнала в области обратных частот  $f_0$  и в области частот  $(f_z-5f_0)-(f_z+5f_0)$  шестерни  $z_2$ ; б) экспериментальные данные, полученные с помощью функции комплекса «Анализ гармоник».

Оптимальное количество нейронов в скрытом слое Кохонена определяется экспериментально, и могут отличаться от разновидности задач, структуры данных и т.д. В нашем случае эксперименты показали хорошие результаты при количестве нейронов в скрытом слое равным 30. Для обучения слоя Кохонена используется конкурентный метод обучения [2], [3]. Суть данного метода обучения заключается в том, что в процессе обучения происходит конкуренция между нейронными элементами, в результате чего определяется нейронный элемент-победитель, который характеризует класс анализируемых данных. Для определения нейрона-победителя используется Евклидово расстояние между входным и весовым векторами, определяемое следующим образом:

$$D_i = |X - a_i| = \sqrt{(X_1 - a_{i1})^2 + (X_2 - a_{i2})^2 + \dots + (X_c - a_{ic})^2}, \quad (1)$$

где  $\omega_{ci}$  – весовой коэффициент между  $c$ -м нейроном распределительного слоя и  $i$ -м нейроном слоя Кохонена;  $X = [X_1, X_2, \dots, X_n]$  – входной образ.

В процессе обучения синаптические связи для нейрона-победителя усиливаются, а для остальных нейронов не изменяются. Таким образом, после обучения ИНС, при подаче входного образа активность нейрона-победителя принимается равной единице, а остальные нейроны «сбрасываются» в ноль [2-4].

- третий слой состоит из одного линейного нейронного элемента, который осуществляет отображение 5 кластеров, сформированных слоем Кохонена. Активность выходного нейрона, когда значение его равно единице, характеризует тот или иной класс. В этом случае все остальные выходные нейроны имеют активность равную нулю.

Из представленных ниже результатов видно, что общая точность классификации разработанного нейросетевого классификатора составляет 92,2%. Причем точность классификации 1-го класса составила 88,9%, 2-го, 3-го и 5-го классов – 100%, а точность классификации 5-го класса – 72,7% (рис. 2, а).

Относительно невысокая точность классификации пятого класса связана со средней квадратичной ошибкой обучения нейронной сети, которая составила 0,00533. Как видно из рис. 2,б, в процессе обучения нейронная сеть не смогла корректно научиться классифицировать образы из 5-го класса, где она показала точность классификации равной 93,3%, что и отразилось на группировании тестового набора данных. Данный недостаток может быть устранен изменением количества нейронов в скрытом слое или увеличением размерности обучающей выборки.

а)

**Confusion Matrix**

Output Class	1	2	3	4	5	
1	8 15.7%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
2	1 2.0%	10 19.6%	0 0.0%	0 0.0%	3 5.9%	71.4% 28.6%
3	0 0.0%	0 0.0%	11 21.6%	0 0.0%	0 0.0%	100% 0.0%
4	0 0.0%	0 0.0%	0 0.0%	10 19.6%	0 0.0%	100% 0.0%
5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	8 15.7%	100% 0.0%
	88.9% 11.1%	100% 0.0%	100% 0.0%	100% 0.0%	72.7% 27.3%	92.2% 7.8%
	1	2	3	4	5	
	Target Class					

б)

**Training Confusion Matrix**

Output Class	1	2	3	4	5	
1	15 20.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
2	0 0.0%	15 20.0%	0 0.0%	0 0.0%	1 1.3%	93.8% 6.3%
3	0 0.0%	0 0.0%	15 20.0%	0 0.0%	0 0.0%	100% 0.0%
4	0 0.0%	0 0.0%	0 0.0%	15 20.0%	0 0.0%	100% 0.0%
5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	14 18.7%	100% 0.0%
	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	93.3% 6.7%	98.7% 1.3%
	1	2	3	4	5	
	Target Class					

Рисунок 2 - Результаты работы искусственной нейронной сети: а) результаты решения задачи классификации; б) результаты обучения нейросетевого классификатора

Таким образом, разработанная методика диагностирования элементов исследуемого объекта с использованием искусственных нейронных сетей показала свою высокую эффективность. Определение диагностируемого параметра с помощью нейросетевых моделей диагностируемого объекта показало высокую точность. Данный подход в диагностике многозубчатых приводов позволит отказаться от трудоемкого экспертного анализа акустических данных и повысить объективность принятия решения. Несмотря на то, что этот метод требует большого объема предварительных исследований, обучения сети, определения технологии подготовки данных, обучив нейронную сеть, ее можно в дальнейшем использовать для постановки диагноза на основе новых сведений.

#### **СПИСОК ЦИТИРОВАННЫХ ИСТОЧНИКОВ**

1. Драган А.В., Стецко И.П., Ромашко Д.А., Левкович Н.В. Новые аппаратно-программные средства для исследования и диагностики механических систем // Вестник Брестского государственного технического университета. — 2006. — №4. — С. 17—26.
2. Kohonen, T. Self-organized formation of topologically correct feature maps / T. Kohonen // Biological Cybernetics. — 1982. — N43. — P. 59-69.
3. Головкин, В.А. Нейронные сети: обучение, организация, применение / В.А. Головкин // Нейрокомпьютеры и их применение : учеб. пособие / В.А. Головкин. — М., 2001 — 256 с.
4. Хайкин, С. Нейронные сети: полный курс / С. Хайкин. — М.: Вильямс, 2006. — 1104 с.

УДК 621.762

### **ТЕРМОСТОЙКИЕ ПОКРЫТИЯ, ФОРМИРУЕМЫЕ НА ОСНОВЕ РЕФРАКТОРНЫХ МЕТАЛЛОВ**

*Чекан Н.М.<sup>1</sup>, Овчинников Е.В.<sup>2</sup>, Акула И.П.<sup>1</sup>, Эйсымонт Е.И.<sup>2</sup>, Шагойка Г.А.<sup>2</sup>*

1) ФТИ, г.Минск, РБ

2) Гродненский государственный университет им. Янки Купалы, Гродно, РБ

Поверхностная, структурная и химическая модификация материалов, нанесение тонких плазмохимических покрытий на рабочие поверхности изделий являются одним из наиболее эффективных технологических методов повышения их эксплуатационных свойств [1-3]. При этом достигаемый эффект зависит от большого числа факторов, среди которых наиболее важным является выбор оптимальных по химическому составу и свойствам материала покрытия и технологии его формирования.

Основными особенностями как тонких металлических, так и полимерных покрытий являются их достаточно высокая структурная неоднородность, зависимость свойств от толщины слоя и природы материала подложки, на поверхность которой они осаждаются. Под действием поля твердой поверхности в слоях тонкослойного покрытия, находящихся в контакте с подложкой (граничных слоях), протекают специфические процессы структурной перестройки [4]. Если толщина покрытия соизмерима с толщиной граничного слоя, то возникает ряд эффектов, обусловленных термодинамической неустойчивостью пленочных систем [5]. Разработка технологических основ процесса упрочнения изделий машиностроения из конструкционных сталей путем нанесения антифрикционных, коррозионностойких покрытий с малым уровнем механических на-