

## КОМПЬЮТЕРНАЯ МОДЕЛЬ АВТОМАТИЗИРОВАННОЙ СИСТЕМЫ ТЕХНИЧЕСКОЙ ДИАГНОСТИКИ МЕХАНИЧЕСКИХ ХАРАКТЕРИСТИК МЕТАЛЛОВ НА ОСНОВЕ ВЕЙВЛЕТ–АНАЛИЗА И НЕЙРОСЕТЕВЫХ ТЕХНОЛОГИЙ

Бабичева И.Ф., Бабичев С.А., Шарко А.В.

**Постановка проблемы.** В настоящее время при разработке различных диагностических систем широкое применение находят новые компьютерные технологии, основанные на современных методах обработки эмпирических данных. Их внедрение способствует повышению скорости и точности обработки информации, автоматизации процесса контроля, что существенно снижает трудоёмкость и стоимость диагностических исследований. Экспертный контроль промышленного оборудования предусматривает наличие следующих этапов: 1) визуальный осмотр объекта с целью обнаружения дефектов, видимых невооруженным глазом; 2) диагностирование опасных участков методами неразрушающего контроля с целью выявления скрытых дефектов; 3) при необходимости проведение выборочных разрывных испытаний, которые подтверждают или не подтверждают предположение эксперта о негодности испытуемого оборудования. Однако количество разрывных испытаний можно существенно сократить, повышая эффективности неразрушающего контроля путём использования современных методов обработки эмпирических данных. К таким методам относятся вейвлет–анализ и нейросетевые технологии. При этом на раннем этапе разработки полезным является создание компьютерной модели системы с целью оценки влияния параметров настройки на точность её работы. Решение этой проблемы соответствует государственным научно–техническим программам, которые сформулированы в законе Украины «Про научную и научно–техническую деятельность» и в законе Украины «Про национальную программу информатизации».

**Анализ последних публикаций. Не решенные части общей проблемы.** В настоящее время существуют системы контроля, основанные на нескольких методах неразрушающих испытаний[1;2]. Основной целью любой системы обработки эмпирических данных является нахождение оптимальной аппроксимирующей зависимости между входными измеряемыми характеристиками и выходными требуемыми данными. На смену статистическим методам обработки данных приходят нейросетевые технологии[3], которые при условии правильной настройки обладают большой скоростью обработки данных и высокой точностью прогноза. Для обучения нейронной сети необходимо предварительно создать базу данных, включающей в себя результаты испытаний неразрушающими методами контроля (входные характеристики) и прочностные (выходные) характеристики изделия, определяемые по результатам разрывных испытаний. Очевидно, что точность прогноза будет выше при увеличении количества входных информативных характеристик. Однако при этом усложняется процесс настройки системы, что повышает трудоёмкость диагностических исследований. В работе [4] авторами разработана методика, позволяющая определить рациональную комбинацию методов неразрушающего контроля прочностных свойств стали, основанная на использовании функции желательности Харрингтона и системы нечеткого вывода. Но в условиях проведения реального эксперимента на точность измерений оказывают влияние различные сторонние факторы, создающие шумовую составляющую эмпирического сигнала. Один из путей понижения уровня шума – уменьшение чувствительности используемого прибора. Однако при этом теряется способность прибора к регистрации мелких дефектов или некоторых локальных особенностей сигнала, несущих информацию об исследуемом объекте.

**Целью статьи** является разработка компьютерной модели автоматизированной системы дефектоскопии механических характеристик металлов акустическим методом не-

разрушающего контроля, в которой очистка сигнала от шумовой составляющей осуществляется при помощи вейвлет–анализа, а окончательное заключение о механических характеристиках объекта производится посредством использования нейросетевых технологий.

**Изложение основного материала.** Создание компьютерной модели предусматривает наличие следующих этапов:

- генерирование сигнала, вид и форма которого максимально приближены к реальному сигналу;
- создание шумовой составляющей и её синтез с сигналом генератора;
- разработка вейвлет–фильтра, включающая в себя подбор типа вейвлета, уровня вейвлет–разложения и выбор порога для удаления шума;
- создание базы данных для обучения нейронной сети;
- выбор типа и структуры нейронной сети, подбор коэффициентов весов и смещений сети, её обучение и тестирование.

Структурная схема компьютерной модели представлена на рисунке 1.

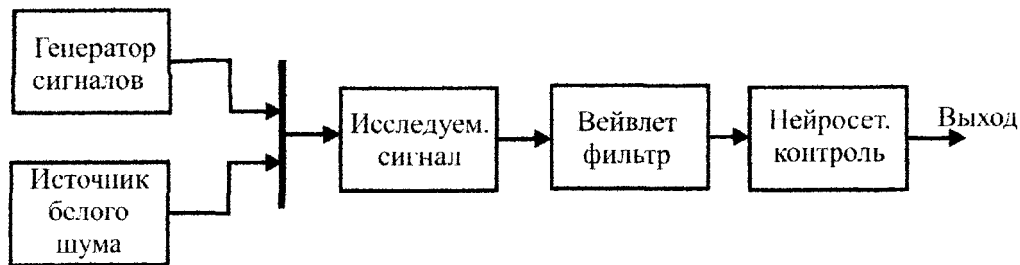


Рис.1. Структурная блок–схема компьютерной модели системы контроля механических характеристик металлов.

При ультразвуковом контроле образца длины  $\ell$  продольными волнами резонансная частота определяется из условия:

$$f = \frac{nC}{2\ell}, \quad (1)$$

где  $n$  – число длин полуволн, укладываемых на длине изделия при резонансе,  $C$  – скорость распространения ультразвука в изделии. Из формулы (1) следует, что значение резонансной частоты зависит от длины изделия в направлении прозвучивания, измерить которую в реальных условиях с высокой точностью не всегда возможно. Однако можно показать, что относительное изменение резонансной частоты  $\Delta f/f$  не зависит ни от размеров изделия, ни от частоты прозвучивания. Действительно,

$$\Delta f = \frac{n\Delta C}{2\ell}. \quad (2)$$

Разделив (2) на (1), получаем:  $\Delta f/f = \frac{\Delta C}{C}$ , т.е. относительное изменение резонансной частоты определяется только изменением скорости ультразвука в изделии и не зависит от его размеров. Таким образом, в качестве первой входной акустической характеристики при прозвучивании продольными волнами предлагается использовать относительное изменение резонансной частоты  $\Delta f/f$ . Второй входной характеристикой являлся логарифмический декремент затухания  $\lambda$ :

$$\lambda = \ln \frac{A(t)}{A(t+T)}, \quad (3)$$

где  $T$  – период затухающих колебаний,  $A(t)$  – амплитуда колебаний в заданный момент времени.

Очевидно, что точность контроля возрастает при повышении чувствительности используемого дефектоскопа. Однако повышение чувствительности вызывает появление мешающих шумов, являющихся следствием аппаратурной погрешности используемого оборудования. Полученный на выходе дефектоскопа сигнал может быть представлен следующим образом:

$$s(t) = f(t) + \delta e(t), \quad (4)$$

где  $s(t)$  – исследуемый сигнал,  $f(t)$  – полезный сигнал,  $e(t)$  – шумовая составляющая сигнала,  $\delta$  – коэффициент, определяющий уровень шумовой составляющей исследуемого сигнала.

Для выделения шумовой составляющей использовался вейвлет–анализ[5]. В соответствии с пирамидальным алгоритмом Малла, исходный сигнал подаётся на фильтры декомпозиции низких (L) и высоких (H) частот, после чего с помощью операции децимации  $\downarrow 2$  получаем коэффициенты аппроксимации ( $cA$ ) на выходе фильтра низких частот и детализирующие коэффициенты ( $cD$ ) на выходе фильтра высоких частот. Далее этот алгоритм продолжается по предложенной схеме до уровня декомпозиции  $k+1$ . На уровне вейвлет–коэффициентов вейвлет разложение сигнала представляется следующим образом:

$$P_j(f) = cA_0 \rightarrow \{cA_1, cD_1\} \rightarrow \{cA_2, cD_2, cD_1\} \rightarrow \dots \rightarrow \{cA_N, cD_N, cD_{N-1}, \dots, cD_1\} \quad (5)$$

Решение задачи выполнялось в четыре этапа:

1. исходный сигнал разлагался по базису вейвлетов.
2. выбиралось пороговое значение шума для каждого уровня разложения;
3. производилась пороговая фильтрация коэффициентов детализации;
4. реконструкция сигнала.

Выбор используемого вейвлета и глубины разложения зависит от свойств конкретного сигнала. Более гладкие вейвлеты создают более гладкую аппроксимацию сигнала, и наоборот, «короткие» вейвлеты лучше отслеживают пики аппроксимируемой функции. Глубина разложения влияет на масштаб отсеиваемых деталей. При увеличении глубины разложения модель вычитает шум все большего уровня, при этом возможно сглаживание не только шума, но и некоторых локальных особенностей сигнала. Для вейвлет преобразования необходимо вычислить серию аппроксимирующих и детализирующих вейвлет–коэффициентов  $\{cA_N, cD_N, cD_{N-1}, \dots, cD_1\}$ . Каждый коэффициент находится следующим образом:

$$a_{j-N,k} = \int_R f(x) \overline{\varphi_{j-N,k}(x)} dx \quad (6)$$

$$d_{j-m,k} = \int_R f(x) \overline{\psi_{j-m,k}(x)} dx, \quad m = 1, 2, \dots, N. \quad (7)$$

Восстановление функции  $f(x)$  производится с использованием изменённых вейвлет–коэффициентов разложения сигнала:

$$f(x) = \sum_{k \in Z} a_{j-N,k} \varphi_{j-N,k}(x) + \sum_{k \in Z} d_{j-N,k} \psi_{j-N,k}(x) + \dots + \sum_{k \in Z} d_{j-1,k} \psi_{j-1,k}(x) \quad (8)$$

Шумовая компонента сигнала в большинстве случаев отражается в детализирующих коэффициентах  $cD_j$ , вследствие чего именно они подвергаются обработке. Кроме того, шумовая компонента представляет собой сигнал, меньший по модулю, чем основной. Поэтому для удаления шума необходимо сделать нулевыми значения коэффициентов, меньшие некоторого порогового значения. От выбора порогового уровня фона зависит качество шумоподавления сигнала, оцениваемое в виде отношения сигнал/шум. Задание малого значения порога сохраняет фон в коэффициентах детализации и поэтому приводит лишь к незначительному увеличению отношения сигнал/шум. При больших значениях порога можно потерять коэффициенты, которые несут существенную информацию. Поиск оптимального значения порога сводится к нахождению наибольшего значения отношения сигнал/шум при наименьшем смещении восстановленного сигнала.

Поставленная задача авторами решалась в СКМ MATLAB с использованием пакета для обработки сигналов и изображений Wavelet Toolbox. Для выбора оптимального вейвлет–разложения использовался критерий энтропия – логарифм энергии:

$$E = \sum \log(s_i^2) \quad (9)$$

Энтропия исходного сигнала принимает максимальное значение по причине его зашумленности. При увеличении уровня вейвлет–разложения энтропия уменьшается до минимального значения, которое соответствует наиболее оптимальному уровню вейвлет–декомпозиции исходного сигнала. Для удаления шума использовался метод Бирге–Массарта, в соответствии с которым определялось пороговое значение критерия  $\tau$  для обработки детализирующих вейвлет–коэффициентов. Значения коэффициентов, меньшие выбранного порогового значения, делались нулевыми, а значения остальных коэффициентов уменьшались на величину  $\tau$ . Оптимальное значение критерия  $\tau$  выбиралось по принципу минимальной энтропии – логарифма энергии. Для выбора оптимального вейвлета, позволяющего получить наилучший уровень вейвлет–очистки сигнала от шума использовался критерий: отношение энтропий оригинального и очищенного от шума сигналов:

$$\eta = \frac{E_0}{E} \quad (10)$$

На первом этапе отбиралось для каждого типа вейвлетов наилучшее дерево по критерию: энтропия – логарифм энергии. Использовались ортогональные вейвлеты с компактным носителем: Добеши (db), Симплета (sym), Койфлетса (coif). Энтропия рассчитывалась для каждого уровня вейвлет–разложения сигнала при различных значениях порогового критерия  $\tau$ . На рисунке 2 представлены графики исходного сигнала (а), зашумленного (b) и очищенного от шума (с), а также графики зависимости энтропии – логарифм энергии от уровня декомпозиции сигнала (d) и значения порогового критерия  $\tau$  (е). Обработка производилась вейвлетом Симплета (sym5).

На втором этапе по формуле (10) для каждого типа вейвлетов и на различном уровне вейвлет–декомпозиции сигнала рассчитывался критерий  $\eta$  – отношение энтропий. График зависимости критерия  $\eta$  от типа используемого вейвлета представлен на рисунке 2(f).

Анализ графиков позволяет сделать вывод, что наименьшая энтропия сигнала наблюдается при использовании вейвлета Симплета–5, глубине разложения, равной 6 и значении порогового критерия  $\tau = 9$ . Полученные результаты подтвердились визуальным сопоставлением графика вейвлет обработанного сигнала с графиком оригинального сигнала при использовании различных вейвлетов, разных уровней вейвлет–разложения и различных значениях порогового критерия очистки от шума.

Прочностные характеристики металлов определялись с использованием нейросетевых технологий. Применение нейронных сетей предусматривает выполнение следующих этапов:

- определить входной вектор нейронной сети. Входным вектором является набор эмпирических данных, полученных в процессе неразрушающего контроля. Размерность вектора определяется количеством измеряемых параметров, в данном случае она равна двум;
- определить выходной вектор сети, в качестве которых используются требуемые механические характеристики исследуемого металла;
- определить тип и структуру сети: число слоёв, связи между слоями, задать начальные весовые коэффициенты и смещения, функцию ошибки системы, и т.д.;
- определить критерий качества и функционал её оптимизации, зависящий от ошибки;
- обучить сеть, в процессе чего определяются смещения и весовые коэффициенты до получения требуемой точности прогноза.

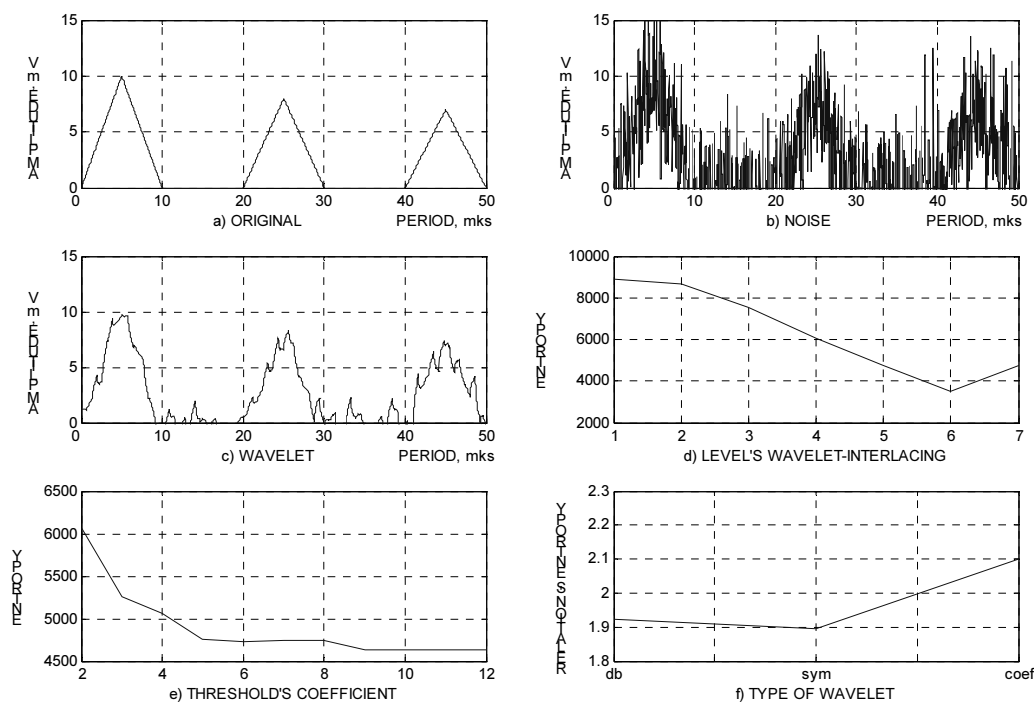


Рис.2. Графики моделей оригинального (а), зашумленного (b) и очищенного от шума (с) сигналов, зависимости энтропии от уровня вейвлет–разложения (d) и энтропии от значения порогового критерия очистки от шума (е), зависимости коэффициента отношения энтропий  $\eta$  от типа вейвлетов (f).

В результате обучения нейронная сеть становится способной в момент времени  $t$  вычислять упрежденные значения функции на временном интервале  $[t+1, t+\alpha]$  при подаче на её вход значений функции  $F$  из интервала  $[t-T+1, t]$ , где  $\alpha$  – длина интервала упреждения,  $T$  – длина интервала наблюдения. Входной сигнал нейронной сети – это вектор значений функции  $F$  на интервале  $[t-T+1, t]$ :

$$\bar{\xi}_2(t) = \{F(t-T+1), F(t-T+2), \dots, F(t-1), F(t)\}. \quad (11)$$

Выходной сигнал нейронной сети в момент времени  $t$  – это вектор аппроксимированных нейронной сетью упрежденных на интервале  $[t+1, t+\alpha]$  значений функции  $F$ :

$$\bar{e}(t) = \{\bar{e}_1(t), \bar{e}_2(t), \dots, \bar{e}_n(t)\} \quad (12)$$

Желаемый выходной сигнал нейронной сети в момент времени  $t$  – это вектор значений функции  $F$  на интервале  $[t+1, t+\alpha]$ . Ошибка решения определяется как разность между желаемым и действительным выходными сигналами в дискретный момент времени  $t$ , т.е. ошибка решения показывает расстояние до правильного значения. При настройке весов целью является минимизация значений вектора ошибки на каждом  $n$ -м примере.

Для решения поставленной задачи авторами использовалась персептронная трехслойная нейронная сеть с двумя нейронами в первом слое, четырьмя во втором и одним – в третьем.

**Выводы:** Анализ проведенных исследований показал перспективность использования вейвлет–анализа и нейросетевых технологий для создания автоматизированных систем технической диагностики. Применение современных компьютерных технологий позволило при высокой точности определения механических характеристик автоматизировать процесс контроля, что способствует повышению скорости и уменьшению трудоёмкости диагностических исследований. В перспективе авторы планируют на основе предложенной модели разработать автоматизированную систему технической диагностики меха-

нических характеристик металлов с использованием нескольких методов неразрушающих испытаний.

The opportunities of the wavelet analysis and neural networks use in the automated systems of technical diagnostics of metal mechanical characteristics are considered in the article. The methods of wavelet processing of the one-dimensional signal, which allows to receive the optimal level of wavelet of the decomposition is developed.

1. Шарко А.В. Бабичев С.А. К вопросу о возможности построения комплексных акустических систем технической диагностики металлопродукции. – Автоматика, Автоматизация, Электротехнические комплексы и системы.–1997г. №1.– С. 184–190.
2. Ключев В.В. Неразрушающий контроль и диагностика безопасности.– Завод. лабор. Диагностика материалов.– 1998, №1– С. 16.
3. Круглов В. В. Борисов В. В. Искусственные нейронные сети.– М.: Горячая линия – Телеком. 2001 г.
4. Бабичев С.А. Разработка автоматизированной системы технической диагностики прочностных характеристик металлов.– Вестник ХГТУ, 2003, №18.– С. 154–162
5. Смоленцев Н.К. Основы теории вейвлетов. Вейвлеты в MATLAB.–М.: ДМК,2005.– 298с.