

КЛАССИФИКАЦИЯ ТЕКСТУР В ПРОСТРАНСТВЕ ИНФОРМАТИВНЫХ ПРИЗНАКОВ ВЕЙВЛЕТ- ПРЕОБРАЗОВАНИЯ

Запропоновано використання вейвлет-перетворення при формуванні інформативних ознак для класифікації текстур. Розглянуто застосування імовірнісних нейронних мереж для побудови класифікаторів текстур. Запропонований підхід використано для аналізу зображень зламів різних фізичних матеріалів.

Предложено использование вейвлет-преобразования при формировании информативных признаков для классификации текстур. Рассмотрено применение вероятностных нейронных сетей для построения классификаторов текстур. Предложенный подход использован для анализа изображений изломов различных физических материалов.

Usage wavelet transformation at shaping informative indications for classification of textures is offered. The application of probability neural networks for construction textures classifiers is considered. The offered approach was used for the analysis of the breaks images of different physical materials.

В настоящее время существенно возрастают требования к надежности и значительно ужесточаются условия эксплуатации механизмов и машин. В результате чрезвычайно актуальной стала проблема создания материалов, видов их обработки, обеспечивающих достаточную надежность против разрушения. Именно поэтому в последние годы большое значение придается изучению процесса разрушения и влияния структурных и технологических факторов на характеристики разрушения [3].

Среди физических методов изучения связи состава и структуры материала с его механической прочностью особое место отводится исследованию поверхностей разрушения (изломов), поскольку излом наиболее четко отражает строение и свойства материала в локальном объеме, в котором протекает процесс разрушения. Изучают изломы и выявляют их закономерности с различных точек зрения, зависящих от решаемых задач: для оценки металлургического качества материала, определения температурных интервалов хладноломкости или отпускной хрупкости, для выяснения причин разброса механических свойств при определении вязкости разрушения и т. д.

Успешному развитию исследований изломов способствует использование современных физических методов (электронная микроскопия, рентгеноструктурный анализ и т.д.), а также методов обработки получаемых изображений изломов с применением современных информационных технологий. Наиболее общая черта практически всех изломов заключается в неод-

нородности их строения, обусловленной наличием зон с различным составом, структурой и свойствами, что и учитывается при оценке дефектности материала для различных видов технологического контроля. По наблюдаемому микростроению изломов можно классифицировать виды разрушения материала и т.д. Примеры изображений изломов представлены на рис.1 [3]. Для анализа излома важны его свойства как текстуры.

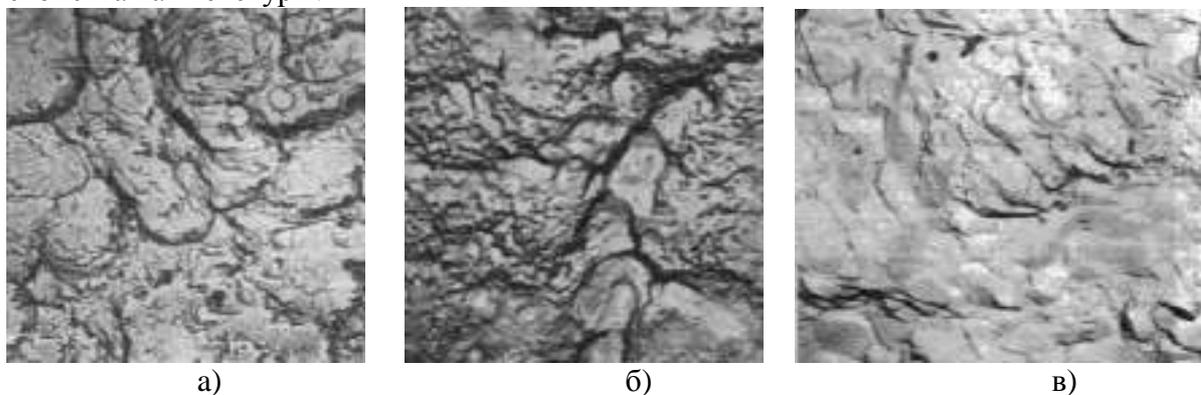


Рис. 1. Изображения изломов

Следует отметить, что не существует строгого определения понятия текстура, однако наиболее принятым является следующее: «под текстурой понимается организованный участок поверхности» [5]. Традиционно принятая классификационная типологическая схема включает следующие виды текстурных изображений: случайные, периодические, квазипериодические и смешанные. Методы классификации текстурных изображений основаны на следующих моделях [1, 5]: структурной (текстура — совокупность структурных элементов), стохастической (изображение рассматривается как реализация случайного процесса), спектральной (анализируется частотный состав изображения).

Авторами рассмотрена возможность использования вейвлет-преобразования для решения задачи анализа излома как текстуры, так как это преобразование дает возможность подчеркивать структурные элементы текстуры и проводить анализ с разным разрешением.

При построении систем автоматизированного анализа изображений поверхностей классификация естественных текстур является сложной задачей [1, 5]. Ее решение предусматривает разработку методов выделения инвариантных информативных признаков и количественных характеристик изображения и методов классификации, обеспечивающих высокую достоверность. Построение систем анализа требует проведения предварительного анализа изображений; выбора и обоснования базовых процедур системы и носит исследовательский характер.

Исходными данными для предварительного анализа изображений являются цель анализа и представительная выборка класса обрабатываемых изображений. В результате предварительного анализа формируется обучающая выборка. На рис. 2 представлены наиболее типичные изображения однородных областей-эталонов, включенных в обучающую выборку. Размер эталонных областей определяется масштабом съемки и требованиями достаточного отражения свойств и особенностей текстурной области.

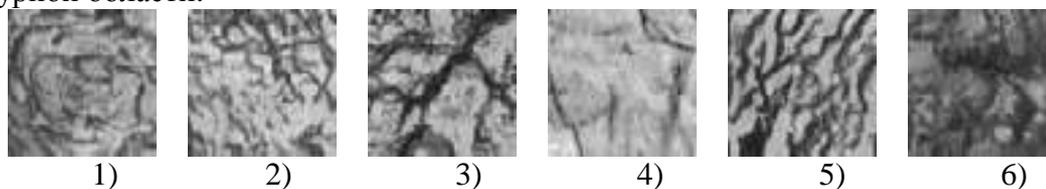


Рис. 2. Эталоны областей текстур

Для анализа изломов необходимо решить задачу классификации текстурных областей на изображении, решение которой проводится в два этапа.

Этап 1. Расчет информативных признаков.

В настоящее время большая часть задач цифровой обработки сигналов-изображений решается при помощи вейвлет-анализа [4], широкое использование которого связано с тем, что его базис – разные версии и сдвиги функций двух типов (скейлинг-функции и вейвлета) – более отвечает природе изображений, чем периодические функции, поскольку изображения есть набор элементов разного положения и размера. В рамках обработки сигналов в настоящее время развит дискретный вейвлет-анализ, построены банки вейвлет-фильтров, заложены основы теории вейвлет-пакетов, целочисленного вейвлет-преобразования.

Как известно [4], обработка двумерных изображений прямым дискретным вейвлет-преобразованием предусматривает преобразование исходного изображения A размерностью $2m \times 2n$ пикселей в четыре изображения размерами $m \times n$: низкочастотное по горизонтали и вертикали (НН), высокочастотное по горизонтали и вертикали (ВВ), низкочастотное по горизонтали и высокочастотное по вертикали (НВ) и высокочастотное по горизонтали и низкочастотное по вертикали (ВН). НН содержит аппроксимацию исходного изображения A с уменьшенным в два раза разрешением, а три остальных содержат детализирующие элементы A соответственно диагонального, горизонтального и вертикального направлений (рис. 3). Этот процесс происходит следующим образом. Сначала каждая из $2m$ строк изображения делится на низкочастотную и высокочастотную половины. Получается два изображения H_k, V_k размерами $m \times 2n$. Далее, каждый столбец делится аналогичным образом. При многоуровневом вейвлет-преобразовании обычно первое из вышеназванных изображений делится аналогичным образом на следующем шаге преобразования и т.д.

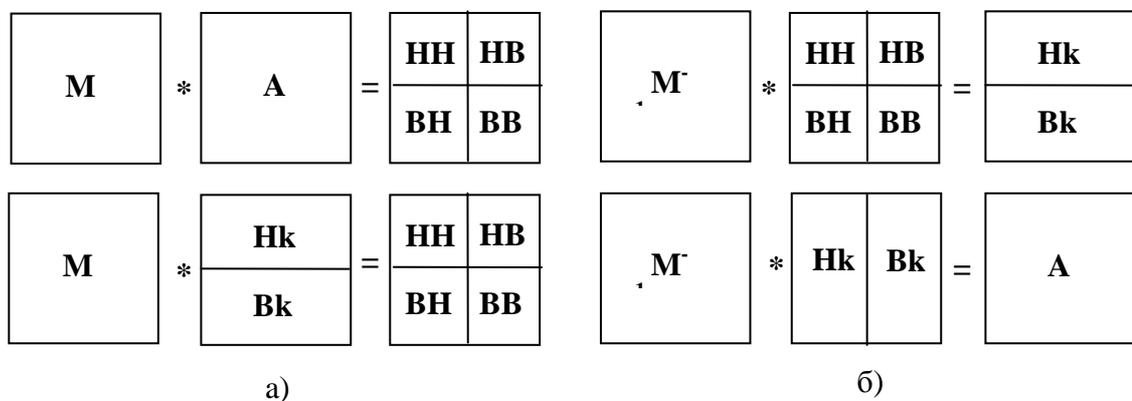


Рис. 3. Матричное представление прямого (а) и обратного (б) вейвлет – преобразования изображения

Прямое и обратное вейвлет-преобразование изображения A может быть представлено в матричном виде:

прямое преобразование
$$\begin{bmatrix} \mathbf{НН} & \mathbf{НВ} \\ \mathbf{ВН} & \mathbf{ВВ} \end{bmatrix} = \mathbf{M} \cdot (\mathbf{M} \cdot \mathbf{A})^T,$$

обратное преобразование
$$\mathbf{A} = \mathbf{M}^{-1} \cdot \left(\mathbf{M}^{-1} \cdot \begin{bmatrix} \mathbf{НН} & \mathbf{НВ} \\ \mathbf{ВН} & \mathbf{ВВ} \end{bmatrix} \right)^T,$$

где \mathbf{A} , $\mathbf{НН}$, $\mathbf{НВ}$, $\mathbf{ВН}$, $\mathbf{ВВ}$ – матрицы исходного и преобразованного изображений, \mathbf{M} – матрица преобразования.

Матрица \mathbf{M} в свою очередь состоит из двух прямоугольных матриц \mathbf{H} и \mathbf{G} размерностью $m \times 2m$, построенных на основе коэффициентов h_i и g_i фильтров, используемых для выделения низкочастотных составляющих (h_i) и высокочастотных составляющих (g_i). Между коэффициентами h_i и g_i длиной l существует зависимость [4]: $g_i = (-1)^{i+1} h_{l-i+1}$. Например, для анализа изображений размером 8×8 пикселей и длине анализируемых фильтров $l=4$ матрица \mathbf{M} имеет вид:

$$\mathbf{M} = \begin{pmatrix} h1 & h2 & h3 & h4 & 0 & 0 & 0 & 0 \\ 0 & 0 & h1 & h2 & h3 & h4 & 0 & 0 \\ 0 & 0 & 0 & 0 & h1 & h2 & h3 & h4 \\ h3 & h4 & 0 & 0 & 0 & 0 & h1 & h2 \\ h4 & -h3 & h2 & -h1 & 0 & 0 & 0 & 0 \\ 0 & 0 & h4 & -h3 & h2 & -h1 & 0 & 0 \\ 0 & 0 & 0 & 0 & h4 & -h3 & h2 & -h1 \\ h2 & -h1 & 0 & 0 & 0 & 0 & h4 & -h3 \end{pmatrix}.$$

Верхняя половина матрицы \mathbf{M} соответствует матрице \mathbf{H} , нижняя – матрице \mathbf{G} . В качестве фильтров можно использовать различные базисные функции (Харра, Добеши и др.).

В области дискретного вейвлет-преобразования (ДВП) рассчитываются информативные признаки. Исследовалась значимость ряда энергетических, информационных и статистических показателей [5]. В качестве информативных признаков использовались: математическое ожидание \bar{a} , дисперсия σ^2 , удельная

энергия $E = \frac{\sum_{i=1}^n \sum_{j=1}^m a(i, j)^2}{m \cdot n}$, удельная энтропия $\mathcal{E} = \frac{\sum_{i=1}^n \sum_{j=1}^m |a(i, j)| \cdot (\lg(0.1 + |a(i, j)|))}{m \cdot n}$,

количество коэффициентов ДВП, превышающих по модулю заданный порог (mz), и их отношения ($\mathcal{E}m = \frac{\mathcal{E}}{mz}$, $Em = \frac{E}{mz}$, $Ed = \frac{\sigma}{E}$, $md = \frac{\bar{a}}{\sigma^2}$, $E\mathcal{E} = \frac{E}{\mathcal{E}}$).

В качестве иллюстрации на рис. 4 представлены зависимости изменения двух признаков для различных видов текстур (номер кривой соответствует номеру эталона) от порядкового номера в обучающей выборке (по 17 моделей каждого из 6 видов) для базиса вейвлета Добеши 9.

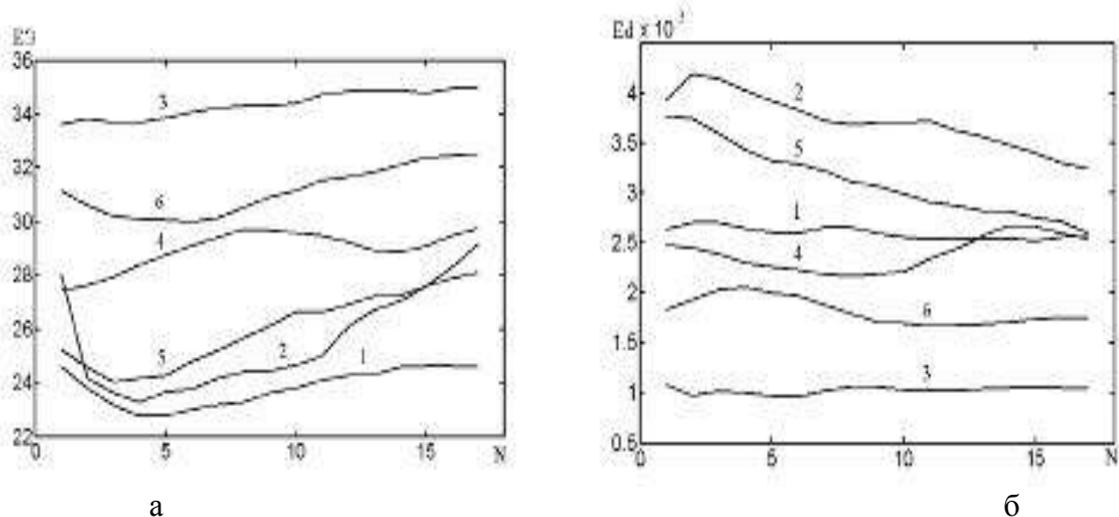


Рис. 4. Информативные признаки для различных эталонов текстур

Анализ полученных результатов свидетельствует, что выбранные параметры достаточно стабильно описывают характеристики текстуры и могут быть использованы для дальнейшей классификации. Пересечение кривых в некоторых точках рис. 4 объясняется тем, что обучающая выборка формировалась с использованием реальных изображений, и отдельные эталоны могут иметь достаточно сильные шумовые искажения.

Исследование влияния выбора базисных функций (вейвлеты Харра, Добеши (2 – 14 порядка), биортогональные вейвлеты и др.) и уровня разложения (от 1 до 4) на формирование системы информативных признаков позволили сделать вывод о целесообразности использования вейвлетов Добеши 6-9 порядков с уровнем разложения 2 либо 3.

Этап 2. Классификация изображений. В направлении развития современных классификаторов наибольшей популярностью пользуются нейронные сети. Для классификации и распознавания текстур сеть накапливает в процессе обучения знания об основных свойствах этих текстур, представленных системой информативных признаков, рассмотренных выше, и осуществляет их обобщение. При обобщении акцентируются отличия текстур друг от друга, которые и составляют основу для выработки классификационных решений. Поскольку полученные признаки носят вероятностный характер, то использовался классификатор на основе вероятностной нейронной сети (PNN) [2]. Сеть PNN базируется на архитектуре радиально-базисной сети, но в качестве второго слоя использует так называемый конкурирующий слой, который рассчитывает вероятность принадлежности входного вектора тому или иному классу и сопоставляет вектор с тем классом, вероятность принадлежности к которому выше (рис. 5).

Используемая сеть в первом слое имеет количество нейронов, равное числу элементов Q обучающего множества, а во втором слое — числу классов K . Весовая матрица первого слоя $\mathbf{I}\mathbf{W}_{1,1}$ размером $Q \times R$ формируется с использованием векторов входа из обучающего множества \mathbf{P} . Когда подается новый входной вектор, блок $\|\text{dist}\|$ вычисляет близость его к векторам обучающего множества, затем вычисленные расстояния умножаются на смещение и подаются на вход функции активации ФА. Вектор обучающего множества, наиболее близкий к вектору входа, будет представлен в векторе выхода \mathbf{a}_1 числом, близким к 1. Произведение весовой матрицы второго слоя $\mathbf{L}\mathbf{W}_{2,1}$ и вектора \mathbf{a}_1 определяет элементы вектора \mathbf{n}_2 , соответствующие каждому из K классов. В результате конкурирующая функция активации КФА второго слоя для самого большого по величине элемента вектора \mathbf{n}_2 формирует на выходе значение 1, в остальных случаях — 0.

Для анализа изображений изломов использовалось обучающее множество \mathbf{P} , состоящее из $Q = 30$ векторов (по 5 на модель), каждый из которых содержал $R=2\dots 8$ компонентов, характеризующих параметры текстуры (коэффициентов разложения). Осуществлялась нормировка каждого параметра для приведения его к диапазону $0\dots 1$.

Результаты классификации представлены в таблице.

Проверка качества классификации проводилась по отношению $\delta = \frac{n_{np}}{n_{общ}}$, где

n_{np} — количество правильно классифицированных текстур; $n_{общ}$ — общее количество классифицируемых текстур. Как показал анализ, наибольшее количество неправильных классификаций приходится на долю второй и пятой текстур, которые очень похожи друг на друга. Проверка предложенной методики на искусственных текстурах показывает правильность тестирования, близкую к 100%.

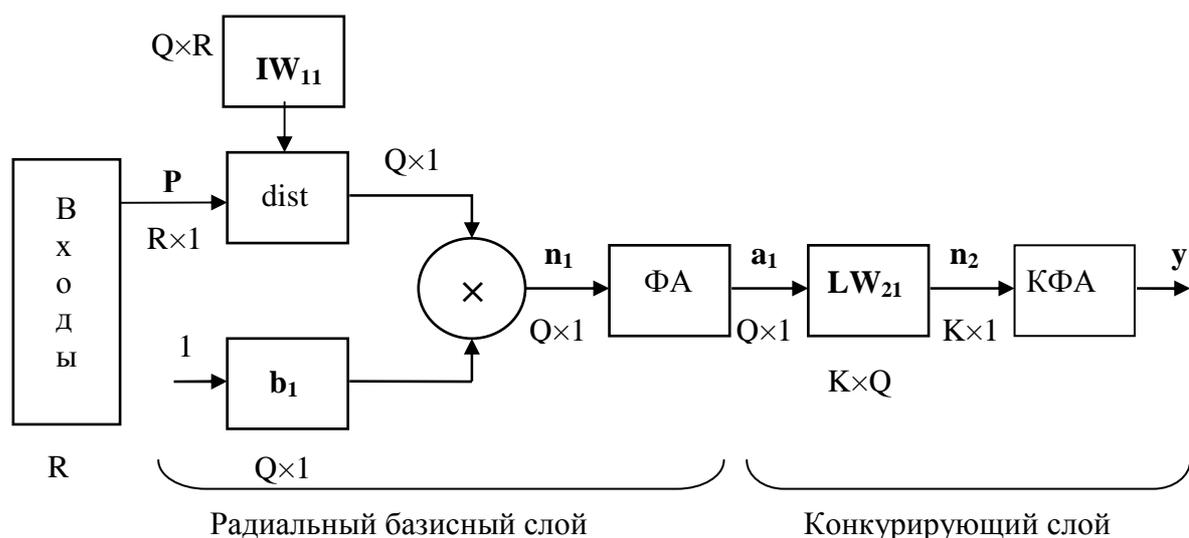


Рис. 5. Структура вероятностной нейронной сети

Объем обучающей выборки	30	30	30	30	30	30	30	30	30	30	300
Распознавание по обученному	29	30	29	30	29	30	28	30	30	28	293
Объем контрольной выборки	23	23	23	23	23	23	23	23	23	23	230
Количество правильно классифицированных текстур	18	20	18	21	23	18	21	20	21	21	201
Качество классификации, %	78	87	78	91	100	78	91	87	91	91	87

Таким образом, проведенные исследования подтвердили целесообразность использования вейвлет-преобразования для анализа и классификации текстур. Рекомендуется для решения этих задач использовать в качестве базисных вейвлеты Добеши 6 – 9 порядков с уровнем разложения 2 либо 3. Предложенный подход может найти применение в ряде практически важных приложений.

Список использованной литературы

1. Власенко В.А., Антошук С.Г., Сербина Н.А. Анализ признаков формы энергетических спектров текстурных изображений //Труды Одес. политехн. ун-та. — 2001. — Вып.1(12) — С.144-147.
2. Галушкин А.Н. Теория нейронных сетей. Москва: ИПРЖР, 2000. — 415 с.
3. Гордеева Т.А., Жегина И.П. Анализ изломов при оценке надежности материалов. — М.: Машиностроение, 1978. — 200 с.
4. Daubechies I. Ten Lectures on Wavelets.SIAM, 1991 (Добеши И. Десять лекций по вейвлетам) — М. — Ижевск: Регулярная и хаотическая динамика, 2001, 350 с.
5. Naralick R.M. Statistical and Structural Approaches to Texture. Proceeding of the IEEE, 67, 1979. — pp. 786-804.

Получено 09.09.04