

УДК 004.032.26

Е.А. Арсирій, канд. техн. наук, доц.,
А.П. Василевская, магистр,
Т.В. Павличенко, специалист,
Одес. нац. политехн. ун-т

ИНТЕЛЛЕКТУАЛЬНЫЙ КЛАССИФИКАТОР СТРУКТУРНЫХ ПРИМИТИВОВ ГИДРОДИНАМИЧЕСКИХ ПОТОКОВ

О.О. Арсирій, О.П. Василевська, Т.В. Павличенко. **Интеллектуальный классификатор структурных примитивов гидродинамических потоков.** Приводится методика построения интеллектуального классификатора (ИК) структурных примитивов гидродинамических потоков за помощью многослойного перцептрона и рекуррентной сети Хопфилда. Моделирование проводилось на реальных изображениях витканья струменя в затопленном пространстве с выделенными вихревыми, комірчастими і орієнтованими областями. Показано, что классификаторы на основе многослойного перцептрона и сети Хопфилда способны решать задачи данного типа.

Е.А. Арсирій, А.П. Василевская, Т.В. Павличенко. **Интеллектуальный классификатор структурных примитивов гидродинамических потоков.** Приводится методика построения интеллектуального классификатора (ИК) структурных примитивов гидродинамических потоков с помощью многослойного перцептрона и рекуррентной сети Хопфилда. Моделирование проводилось на реальных изображениях истечения струи в затопленное пространство с выделенными вихревыми, ячеистыми и ориентированными областями. Показано, что классификаторы на основе многослойного перцептрона и сети Хопфилда способны решать задачи данного типа.

E.A. Arsiry, A.P. Vasilevskaya, T.V. Pavlichenko. **Intellectual classifier of structural primitives of hydrodynamic streams.** The method of constructing intellectual classifier (IC) of structural primitives of hydrodynamic streams with the help of multilayer perceptron and recurrent network of Khopfield is presented. Simulation was conducted on the real images of stream outflow into the submerged space with the selected vortex, cellular and oriented regions. It is shown that classifiers on the basis of multilayer perceptron and network basis of Khopfield are able to solve the tasks of this type.

Наблюдается рост интереса к построению интеллектуальных информационных систем распознавания образов, которые могут решать задачи: локализации определенных объектов в поле изображения, измерения заданных параметров этих объектов, принятия решения по полученным результатам измерений об отнесении объекта к определенному классу, а также на основе полученной информации об изображении содержательной его интерпретации. Задачу классификации объектов (образцов, сигналов) в общем виде можно определить как отнесение наблюдаемых данных к определенному классу на основе выделения существенных признаков, характеризующих эти данные [1]. Решение этой задачи зависит от выбора множества признаков, обеспечивающих компактное представление объектов одного класса в пространстве признаков. Если множество объектов конечно и поддается формальному описанию, можно разработать формальные правила классификации, например, в зависимости от максимальных и минимальных значений компонент выделенных признаков и т.п. Кроме формального подхода для решения задач классификации может быть также использован геометрический метод, основанный на вычислении расстояния в качестве меры сходства векторов признаков, представляющих объекты [1, 2]. Результаты подобной классификации будут удовлетворительными, если соблюдается условие компактности, т.е. точки, представляющие объекты одного класса, расположены к друг другу ближе, чем к точкам, представляющим объекты другого класса. Вторым условием является существование непересекающихся между собой классов. Классическим методом, используемым для решения задач разделения множества объектов на классы, является байесовский классификатор или байесовская процедура проверки гипотез, основанная на знании стати-

стических свойств классов [1, 2]. Недостатком байесовского классификатора является его параметричность, т.е. требование, чтобы форма распределения множества объектов одного класса была гауссовой. Интеллектуальные классификаторы (ИК), построенные на основе искусственных нейронных сетей (ИНС), — универсальное средство аппроксимации функций, что позволяет их использовать в решении задач классификации наряду со статистическими методами [1, 2]. Однако ИК более эффективны, т.к. генерируют фактически большее число регрессионных моделей и не являются параметрическими, т.е. не выдвигают никаких предварительных предположений относительно формы распределений признаков классифицируемых объектов.

Известна информационная технология визуализации и автоматизированной идентификации вихревых волновых структур, которая обеспечивает эффективный анализ сложных изображений гидродинамических потоков с помощью структурно-спектральных моделей [3]. Построены полностью изотропные, квазиизотропные и анизотропные структурно-спектральные модели, а также аддитивные модели на их основе. Проведены эксперименты и построены кластеры распределения информативных идентификационных параметров моделей, иллюстрирующие возможность эффективной классификации различного типа структурных примитивов гидродинамических потоков. В то же время ИК, построенные с помощью ИНС двух архитектур: многослойного персептрона (Multiple layer perceptron — MLP) и однослойной рекуррентной ИНС, которую называют также сетью Хопфилда, для решения задачи распознавания характерных букв кириллицы показали высокие результаты [4].

Предлагается методика построения ИК для классификации структурных примитивов гидродинамических потоков [3] с помощью архитектур ИНС MLP и сети Хопфилда [4].

Обобщенно методику можно представить в виде последовательности информационных преобразований: формирование входной информации; предварительная обработка входной информации; формирование векторов признаков обучающей выборки; формирование векторов признаков тестовой выборки; выбор архитектуры ИНС; формирование ИНС; обучение либо инициализация ИНС с помощью обучающей выборки; тестирование ИНС на тестовой выборке; представление результатов графическими средствами MATLAB; анализ результатов.

Формирование входной информации. С помощью видеоинформационной системы на основе морфологического анализа изображений истечения потока в затопленное пространство можно выделить следующие виды структурных примитивов — вихревой, ячеистый, ориентированный, под которыми понимаются элементарные, непроектируемые элементы изображений потока жидкости. Размеры элементов изображения лежат в диапазоне (64×64) ... (128×128) пикселей и согласованы, с одной стороны, с разрешающей способностью видеоинформационной системы (в исходном пространстве), а с другой — с характерными размерами волновых вихревых структур, обеспечивающих стационарность изображения примитива.

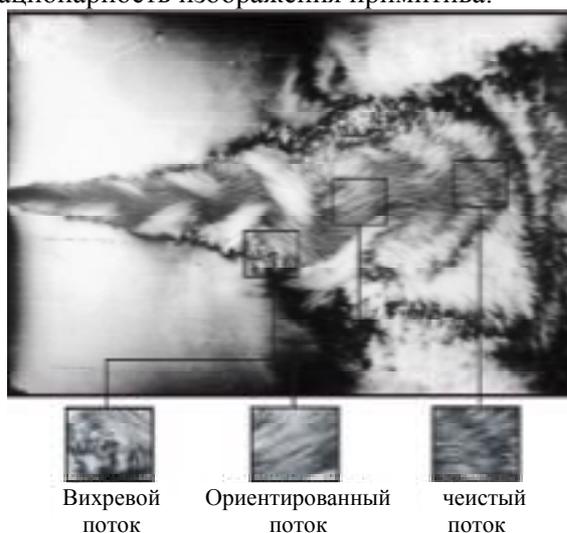


Рис. 1. Выделение структурных примитивов изображения истечения струи в затопленное пространство

Визуализация вихревых волновых структур сочетает метод визуализации дискретных структур потоков (МВДСП), использующий пространственную модуляцию поляризованного света тонким слоем оптически-активной жидкости для получения визуальных картин и видеоинформационную систему для фиксации и интерпретации пространственных и динамических полей перемещения рабочего тела, а также для получения количественных динамических характеристик этого перемещения [3].

Предварительная обработка входной информации. На основании исходных изображений структурных примитивов (рис. 2, а), осуществляется вычисление спектральной плотности по Фурье с подавлением ее малоинформативной постоянной составляющей и представлением в логарифмическом масштабе (б), затем выполняется двумерная медианная фильтрация спектральной двумерной плотности (в). Выбор размера окна для медианного фильтра определен на основе многочисленных практических исследований подобных структурных примитивов в диапазоне $(5 \times 5) \dots (11 \times 11)$ пикселей. В результате пороговой обработки “порог снизу” изображения (в) обрезаются составляющие отфильтрованной спектральной плотности, не превышающие некоторый пороговый уровень. Далее изображение усекается, а затем растягивается до исходных размеров. Для сглаживания неровных границ связанных областей вновь выполняется двумерная медианная фильтрация и проводится пороговая обработка “порог сверху”, в результате которой отсекаются составляющие, со спектральной плотностью выше ранее установленного порога. Полученное бинарное изображение (г) пригодно для формирования вектора классификационных признаков.

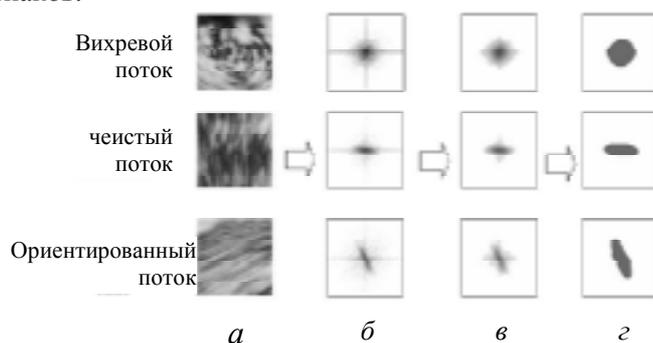
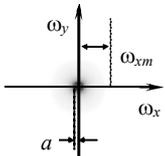
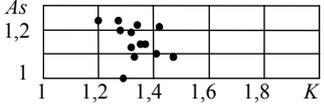
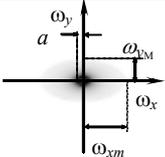
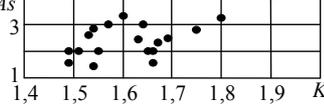
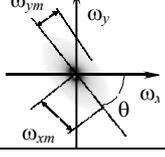
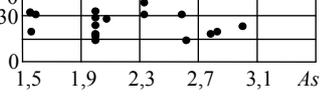


Рис. 2. Последовательность предварительной обработки структурных примитивов гидродинамических потоков: исходное изображение структурного примитива (а), изображение спектральной плотности по Фурье (б), результат выполнения двумерной медианной фильтрации (в), результат пороговой обработки (г)

Формирование векторов признаков обучающей выборки. Аналитические описания топосечений спектральной плотности по Фурье являются основой для синтеза структурно-спектральных моделей (ССМ) структурных примитивов с малым числом легко оцениваемых параметров. Структурные примитивы вихревого потока описываются односвязными полностью изотропными моделями, в качестве параметров которых выступают константа a и длина радиус-вектора $\omega_{хт}$, подлежащие оценке. При этом топосечение реального оцениваемого амплитудного спектра представляет собой круг и является односвязным. Волновые (ячеистые и ориентированные) структурные примитивы описываются квазиизотропными односвязными моделями, характерными для волнового потока с квазиплоским фронтом, перпендикулярным оси $O\omega_x$ или $O\omega_y$. Топосечение спектральной плотности по Фурье таких потоков, являющееся информативным параметром, представляет собой односвязную область в виде эллипса с полуосями $\omega_{хт}$, ω_{yt} , большая ось которого ориентирована вдоль оси $O\omega_x$, а малая — вдоль $O\omega_y$, либо большая ось повернута относительно оси $O\omega_x$ на угол θ , который, наряду с параметром a , большим $\omega_{хт}$ и малым ω_{yt} радиусами, является информативным параметром. Проанализировав кластеры инте-

гральных показателей можно сформировать трехмерное пространство признаков, состоящее из аспекта As , угла наклона θ оси $O\omega_x$ к оси $O\omega_x$ и коэффициента формы K (см. таблицу).

Распределения параметров ССМ структурных примитивов гидродинамических потоков

Структурный примитив	Структурно-спектральные модели		
	Структура	Кластеры интегральных показателей	Формулы расчета
Вихревой			Аспект $As = \frac{\omega_{\max}}{\omega_{\min}}$, где ω_{\max} , ω_{\min} — большой и меньший радиусы связной области
Ячеистый			Коэффициент формы $K = 4\pi \frac{S}{P^2}$, где S — площадь, P — периметр связной области
Ориентированный			Угол наклона $\theta = \arctg \frac{\omega_{\min}}{\omega_{\max}}$

Длина обучающей выборки 48 примеров достаточна, чтобы ИНС не просто запомнила примеры из общей выборки, а приобрела способность к обобщению. Так как ИНС работает с исходными данными, представленными числами в диапазоне $0 \dots 1$, необходимо выполнить линейное преобразование выбранных интегральных показателей в данный диапазон. При формировании обучающей выборки следует выбрать способ кодирования выходных значений — желаемого выхода. Наиболее простым способом представления выходных данных, в этом случае, является вектор, номера компонент которого соответствуют номерам классов. При этом i -я компонента вектора соответствует i -му классу. При интерпретации результата обычно считается, что номер класса определяется номером выхода ИНС, на котором появилось максимальное значение. Например, если ИНС с тремя выходами соответствует вектор выходных значений $(0,2; 0,6; 0,4)$, то максимальное значение примет вторая компонента вектора, значит класс, к которому относится этот пример, — 2. При таком способе кодирования иногда вводится также понятие “уверенности” сети в том, что пример относится к этому классу. Наиболее простой способ определения уверенности заключается в определении разности между максимальным значением выхода и ближайшим к максимальному значению другого выхода. “Уверенность” ИНС в том, что пример относится ко второму классу, определится как разность между второй и третьей компонентой вектора, т.е. $0,6 - 0,4 = 0,2$. Соответственно, чем выше “уверенность”, тем больше вероятность, что сеть дала правильный ответ.

Формирование векторов признаков тестовой выборки. Для формирования векторов признаков тестовой выборки использовалось изображение (рис. 3), каждый фрагмент которого подвергался предварительной обработке (см. рисунок 2), последующему расчету интегральных показателей и их линейному преобразованию в диапазон $0 \dots 1$.

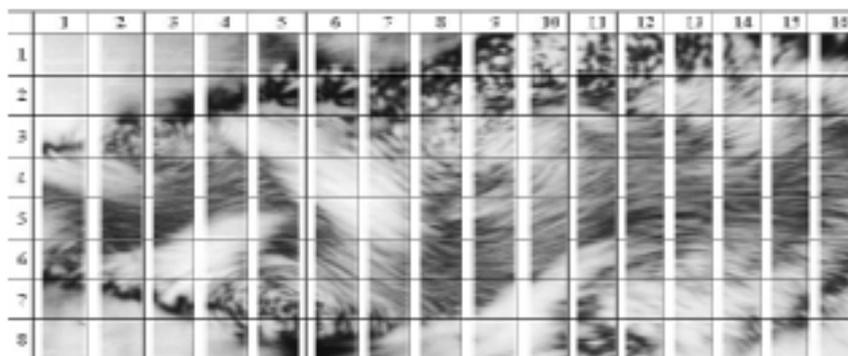


Рис. 3. Фрагменты изображения истечения струи в затопленное пространство

Выбор архитектуры и формирование ИНС. При выборе архитектуры ИНС обычно опробуется несколько конфигураций с различным количеством нейронов и различными видами связи между ними. При этом основными показателями являются объем обучающего множества и обобщающая способность сети. Для обучения ИНС обычно используются алгоритм обратного распространения ошибки (обучение с учителем) или построенные по аналогии с принципами самоорганизации нервных клеток (обучение без учителя) алгоритмы обучения по Хэббу и Кохонену [1, 2].

Существуют два основных подхода к формированию ИНС — конструктивный и деструктивный. В первом сеть минимального размера постепенно увеличивают до достижения требуемой точности результата. При этом на каждом шаге ее заново обучают. Можно также применить метод каскадной корреляции, при котором после окончания эпохи происходит корректировка архитектуры сети с целью минимизации ошибки [1, 2]. При деструктивном подходе из сети завышенного объема постепенно удаляются нейроны и связи, мало влияющие на решение. В обоих подходах необходимо учитывать, что число примеров в обучающей выборке должно быть больше числа настраиваемых весов. Иначе вместо обобщения сеть просто запомнит данные и утратит способность к классификации — результат будет неопределен для примеров, которые не вошли в обучающую выборку. Выбранные архитектуры ИНС сформированы в среде MATLAB.

Обучение либо инициализация ИНС с помощью обучающей выборки и тестирование на тестовой выборке. На основании векторов признаков были сформированы обучающая и тестовая выборки, которые далее использовались для обучения и тестирования или для инициализации и тестирования ИНС двух выбранных архитектур. ИНС MLP с логарифмическими сигмоидальными функциями активации в каждом слое обучалась по алгоритму с обратным распространением ошибки. В ходе эксперимента оптимальными с точки зрения скорости обучения и точности классификации оказались следующие параметры ИНС: три входа — по размеру входного вектора признаков, три нейрона в выходном слое — по размеру выходного вектора признаков, содержащего номер класса, скрытый слой содержал 10 нейронов.

Если задано множество целевых точек равновесия (в данном случае это множество векторов обучающей выборки A_i), то функция библиотеки *NN Tools newhop* возвращает матрицу весов и вектор смещений для рекуррентного слоя сети Хопфилда. Для инициализации рекуррентной сети Хопфилда варьировался размер выборки. Из 48 обучающих примеров вручную выбирались наиболее типичные для своих классов, на которых выполнялась инициализация сети Хопфилда по Хэббу. Наилучшие результаты классификации показала сеть Хопфилда, обученная с помощью всей обучающей выборки 3×48 .

Сформированные и обученные ИНС тестировались на тестовой выборке размером 3×128 , полученной в результате обработки фрагментов изображения (см. рисунок 3). Результаты тестирования ИНС MLP и сети Хопфилда отражены на гистограмме (рис. 4), по оси Y показано общее количество классифицируемых фрагментов, а по оси X — диапазон возможных решений. В “диапазон” I попали все решения, которые можно отнести к правильным с вероятностью

100...75 % “да”, в II, III, IV — с вероятностью 74...50 % “скорее да”, 49...25 % “скорее нет” и 24...0 % “нет”, соответственно. Таким образом, ИНС MLP определила номер класса с вероятностью “да” для 113 из 128 предложенных фрагментов изображений, “скорее да” для 0 фрагментов, “скорее нет” для 3 фрагментов и “нет” для 12 фрагментов изображения. Сеть Хопфилда определила номер класса с вероятностью “да” для 93 из 128 предложенных фрагментов изображений, “скорее да” для 27 фрагментов, “скорее нет” для 5 фрагментов и “нет” для 3 фрагментов изображения.

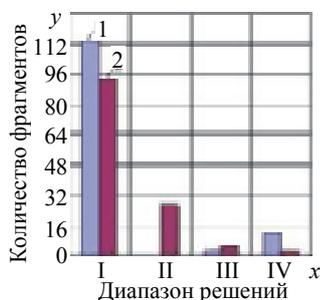


Рис. 4. Результаты тестирования ИНС для классификации структурных примитивов гидродинамических потоков: ИНС MLP(1) и сеть Хопфилда (2)

Анализ результатов экспериментов показывает, что ИК, входящий в информационную технологию визуализации и автоматизированной идентификации вихревых волновых структур, представляет собой следующие блоки: предварительная обработка изображений, формирование векторов признаков для обучающей и тестовой выборки, обучение ИНС на обучающей выборке, тестирование на ИНС тестовой выборке с последующим построением карты решений.

Определены области применения ИК, построенные на ИНС двух указанных архитектур.

ИК, в основу которого положена ИНС MLP, является универсальным средством аппроксимации функций, что позволяет смоделировать более универсальную функцию выбора решения об отнесении предлагаемых образцов к тому или иному классу. ИК, основанный на ИНС MLP, принял правильное решение для 88,2 % образцов из тестовой выборки, и только для 0,02 % образцов не смог однозначно определить номер класса ИНС. MLP, как сеть прямого распространения, является хорошим нелинейным интерполятором входных данных, и если необходимо выделение образа из ряда похожих, служит основой для построения ИК.

Сети Хопфилда используются для решения широкого класса задач, связанных с ассоциативной памятью, т.е. подобно человеческой памяти по заданной части нужной информации вся информация извлекается из “памяти”. Потеря части информации или ее информационное зашумление не приводит к катастрофическому ограничению доступа, если оставшейся информации достаточно для извлечения идеального образа. Основным назначением ИНС Хопфилда являются задачи по обобщению информации. ИК, основанный на сети Хопфилда, принял правильное решение только для 72,6 % образцов из тестовой выборки, а для 25 % образцов не смог однозначно определить номер класса представляемого образца.

Литература

1. Бондарев, В.П. Искусственный интеллект: учеб. пособие для вузов / В.П. Бондарев, Ф.Г. Аге — Севастополь: Изд-во СевНТУ, 2002. — 615с.
2. Хайкин, С. Нейронные сети: полный курс / С. Хайкин; пер. с англ. — 2-е изд., испр. — М.: Вильямс, 2006. — 1104 с.
3. Арсирий, В.А. Автоматизированная идентификация вихревых волновых структур в изображениях гидродинамических потоков для задач технической диагностики / В.А. Арсирий, Е.А. Арсирий, А.П. Василевская / Тр. Одес. политехн. ун-та. — Одесса, 2005. — Вып. 1(23). — С.107 — 112.

4. Арсирий, Е.А. Исследование эффективности искусственных нейронных сетей различных архитектур для распознавания образов / Е.А. Арсирий, А.П. Василевская, Е.Д. Петрова / Холодильна техніка і технологія / Одес. дер. акад. холоду. — Одеса, 2005. — № 6(98). — С. 32 — 38.

Рецензент д-р техн. наук, проф. Одес. нац. политехн. ун-та Антошук С.Г.

Поступила в редакцию 15 марта 2008 г.
