



Л.И. ТИМЧЕНКО, Н.И. КОКРЯЦКАЯ, А.А. ЯРОВОЙ, В.В. МЕЛЬНИКОВ, Г.Л. КОСЕНКО

УДК 658.012:681.32:621.38

МЕТОД ПРОГНОЗИРОВАНИЯ ПОЛОЖЕНИЯ ЭНЕРГЕТИЧЕСКОГО ЦЕНТРА ИЗОБРАЖЕНИЯ ЛАЗЕРНОГО ПУЧКА С ИСПОЛЬЗОВАНИЕМ ПАРАЛЛЕЛЬНО-ИЕРАРХИЧЕСКОЙ СЕТИ

Ключевые слова: *параллельно-иерархическая сеть, изображения пятен лазерных пучков, статистическое наблюдение, временные ряды, прогнозирование.*

ВВЕДЕНИЕ

Возрастающие требования к современным вычислительным средам обусловили разработку новых интеллектуальных методов передачи и обработки информации, а также регулярное обновление систем передачи информации. В настоящее время большинство Интернет-каналов не способны обеспечить необходимого качественного обмена информацией между системами, обрабатывающими информацию в режиме реального времени, что, в свою очередь, приводит к перегрузке данных каналов и образованию так называемых цифровых пробок. Одним из способов решения проблемы передачи больших объемов информации является применение оптоволоконного кабеля.

Данную проблему можно решить с помощью лазерных технологий [1], которые в ближайшее время станут одними из самых перспективных моделей передачи информации. Использование таких технологий позволит, например, за доли секунды передавать десятки полнометражных фильмов и виртуальных сред в любую точку Земного шара. Большинство спутников передают информацию (например, телевизионные программы) с помощью микроволнового излучения, а применяя лазер, это можно делать в сотни раз быстрее, что существенно повлияет на пропускную способность канала передачи.

В случае использования лазера для передачи информации необходимо, чтобы спутник и принимающее устройство находились в определенной позиции. Положение линзы принимающего устройства диаметром всего несколько сантиметров нужно отрегулировать до тысячной доли градуса, иначе передача информации не состоится. Во время процесса отслеживания спутника принимающим устройством, происходящего на всех этапах работы системы, основной задачей является прогнозирование положения изображения пятна лазерного луча, а именно его геометрических характеристик — координат энергетического центра, искажающихся под воздействием турбулентности и воздушных масс. Для решения задачи эффективного прогнозирования целесообразно повысить точность определения центра пятенного объекта с помощью максимального использования его информационных признаков, а также классифицировать кадры последовательности изображений пятен лазерных пучков с целью фильтрации лазерной трассы от изображений, сильно искаженных помехами. Процесс классификация кадров

© Л.И. Тимченко, Н.И. Кокряцкая, А.А. Яровой, В.В. Мельников, Г.Л. Косенко, 2013

предполагает отнесение каждого кадра трассы к одному классу изображений: недеформированные атмосферой — хорошие, деформированные — плохие.

Новый этап развития компьютерных систем прогнозирования в реальном времени обусловил появление высокопроизводительных автоматизированных систем сбора, обработки и хранения информации. Такие системы состоят из совокупности технических средств сбора и обработки информации, способных на основе специально разработанных алгоритмов обеспечить решение задачи классификации и прогноза характеристик соответствующих объектов, явлений или процессов реального времени, используя в основном геометрические свойства границ объектов.

Системы передачи данных с помощью лазерного луча FSO (Free Space Optic) широко применяются и активно развиваются. Однако распространение лазерного излучения в атмосфере сопровождается очень большим набором явлений линейного и нелинейного взаимодействия, что создает значительные помехи при приеме и требует корректировки приемника. В результате этих воздействий лазерный пучок расширяется или расщепляется, поэтому определить координаты его центра, а значит, точно оценить перемещение передатчика, достаточно сложно. Приходится применять различные специальные методы обработки и классификации изображений, которые обычно предназначены для выполнения на стационарных компьютерных системах, где исследователь не ограничен во времени. К тому же оптические системы связи требуют высокопроизводительных портативных устройств обработки информации.

Поэтому актуальна задача разработки такого метода обработки изображений, который, фильтруя деформированные изображения, позволит вычислить и спрогнозировать координаты энергетического центра нечеткого изображения с наилучшей эффективностью и за приемлемое время. В частности, в задачах профилирования лазерных лучей это подтверждают научные исследования и программно-аппаратные разработки таких ведущих корпораций США, как Photon Inc. (San Jose, California), Spiricon Inc. (Logan, Utah), Coherent Auburn Group (Auburn, California), а также результаты их работы, описанные в [2, 3]. Подобные исследования активно осуществляются научными школами различных стран СНГ: например, в России — НПО «Астрофизика», ЗАО «Космические информационные аналитические системы», ФГУП Всероссийский научно-исследовательский институт оптико-физических измерений [4, 5]; в Украине — НИИ лазерной техники и технологии НТУУ «КПИ», Институт физики полупроводников им. В.Е. Лашкарева НАНУ.

Данные исследования актуальны и в области оптических систем связи. Так, в 2005 г. в Лаборатории реактивного движения НАСА провели совместный эксперимент с Японским агентством аэрокосмических исследований (JPL) по установлению двухсторонней оптической линии связи между двумя спутниками. При этом точность позиционирования составляла десятые доли градуса. Во время этого эксперимента также была установлена связь с наземной станцией, однако скорости оставались небольшими: 2 Мбит/с [6]. Поэтому работы по улучшению характеристик таких систем продолжают и в настоящее время учеными дальнего [7] и ближнего зарубежья [8].

Существует много способов прогнозирования [9] величины следующего шага некоторого временного ряда, отличающихся числом необходимых вычислений, погрешностью прогнозирования и количеством шагов, на которые может прогнозировать данный алгоритм. Так, в [10] проанализированы методы прогнозирования временных рядов.

Известны работы по прогнозированию временного ряда событий с применением динамической модели нейронной сети [11]. Результаты показывают, что данный подход перспективен и сравним с лучшими результатами традиционных нейронных сетей.

Интерес к использованию искусственных нейронных сетей (ИНС) [12, 13] для прогнозирования обусловил интенсивное развитие научно-исследователь-

ской деятельности, особенно в последние десятилетия. В то же время применение ИНС имеет много неопределенностей. Большинство исследователей данной проблемы до настоящего времени не уверены в степени влияния основных факторов на эффективность прогнозирования ИНС [13].

В связи с этим в рассматриваемой области исследований необходимы новые альтернативные подходы и методы, конкурентоспособные с ИНС и обеспечивающие наибольшую точность прогнозирования за приемлемое для конкретной задачи время.

Таким новым методом, по-видимому, может стать метод прогнозирования, основанный на применении нейроподобной параллельно-иерархической (ПИ) сети [14].

Представленный далее метод прогнозирования положения энергетических центров фрагментов трасс лазерных пучков используется в системах оптической связи, навигации, локации, а также в военной технике. Разработка системы прогнозирования на основе ПИ сети позволяет решать следующие задачи:

- автоматический контроль объектов;
- передачу данных с помощью лазеров;
- прогнозирование поведения подвижных оптических объектов.

АРХИТЕКТУРА ПИ СЕТИ

Анализ образа (матрицы, составленной из значений связностей пикселей изображения фрагмента лазерной трассы) заключается в последовательном преобразовании совпадающих и выявлении (фильтрации) несовпадающих во времени его составляющих при переходе элементов нейронной сети из текущих энергетических состояний с одними пространственными координатами в состояния с меньшей энергией и другими пространственными координатами.

Условием перехода составляющих образа на следующий уровень ПИ сети является наличие динамики взаимного совпадения промежуточных результатов обработки во времени в одноименных каналах нижнего уровня. Результат анализа образа формируется из изолированных в пространственно-временной области составляющих образа [14].

Параллельно-иерархическая сеть состоит из уровней (рис. 1), а уровни — из параллельных ветвей. Причем, начиная со второго уровня (см. рис. 1, темный круг), каждая формирующаяся последующая ветвь сдвинута во времени относительно предыдущей. Входной образ подается на элементы параллельных ветвей первого уровня, а элементы ветвей второго и последующих уровней формируются последовательно соответственно из элементов ветвей первого и предыдущих уровней. Длина алгоритма ПИ сети и соответственно число ветвей, элементов в них и уровней не являются постоянными величинами, а зависят от характера распределения входных данных.

Основное предназначение ПИ сети — решение задачи быстрого преобразования, классификации и прогнозирования, ориентированной на обработку видеоданных в реальном времени.

На вход ПИ сети (на входные элементы ветвей первого уровня сети (см. рис. 1)) подается вектор входного образа [14, 15] $\mu = \{a_i\}$, $i = 1, n$, применяемого в каждой ветви ПИ сети

$$\sum_{i=1}^n a_i = \sum_{j^*=1}^R \left(n - \sum_{k=0}^{j^*-1} n_k \right) (a^{j^*} - a^{j^*-1}), \quad (1)$$

где $a_i \neq 0$, R — размерность данного множества (число элементов множества) или размерность ветви ПИ сети каждого ее уровня (определяется размерностью входного изображения); a^k , $k = \overline{1, R}$, — элементы подмножеств, состоящих из одинаковых элементов; n_k — число элементов в k -м подмножестве

(т.е. кратность числа a_i); a^{j^*} — элемент множества $\{a^k\}$, выбранный на j^* -м шаге, $j^* = \overline{1, R}$, $a^0 = 0$, $n_0 = 0$.

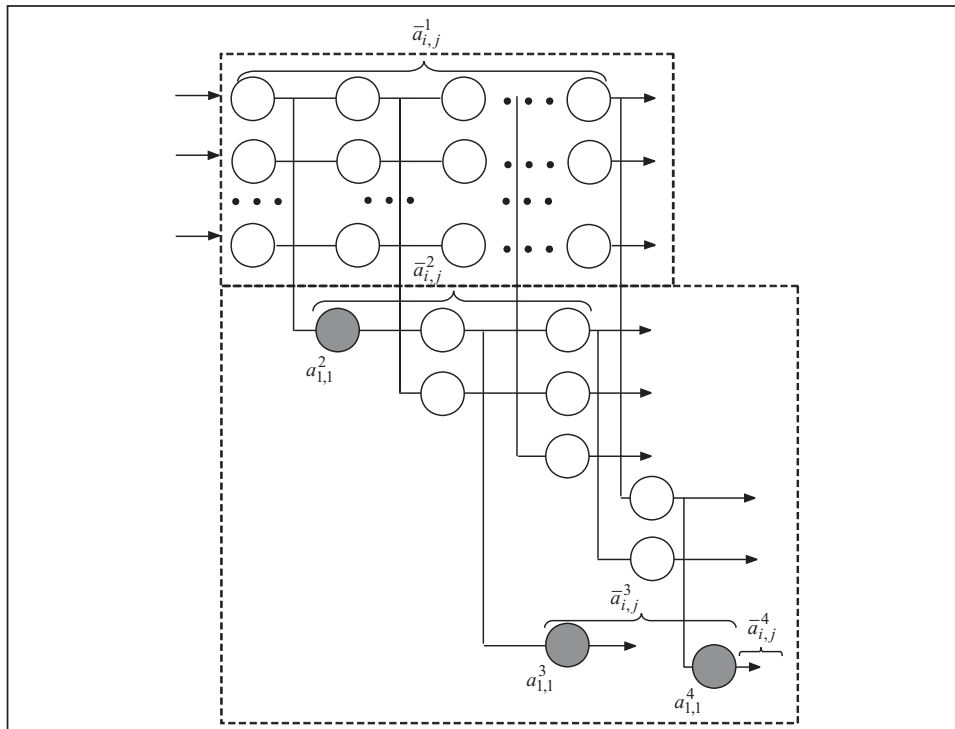


Рис. 1. Структура ПИ сети с усредненными параметрами

Функциональное описание ПИ сети. Рассмотрим преобразование $G(M) = \{a_j | j=1, 2, \dots, m_1\}$, описанное формулой (1), применяемое в каждой ветви ПИ сети. Исходное изображение M представим n сегментами, над которыми преобразование G одновременно выполняется в каждой ветви обработки i , $i=1, \dots, n$, анализируемый i -й сегмент изображения обозначим $M_i^1 = \{a_{ij}^1 | j=1, 2, \dots, m_i^1\}$, где m_i^1 — число компонент в i -м канале первого уровня, а все анализируемые сегменты можно представить в виде матрицы A_1 :

$$A_1 = \begin{bmatrix} M_1^1 \\ M_2^1 \\ \dots \\ M_i^1 \\ \dots \\ M_n^1 \end{bmatrix} = \begin{bmatrix} a_{11}^1 & a_{12}^1 & \dots & a_{1m_1}^1 & x & x & \dots & x \\ a_{21}^1 & a_{22}^1 & \dots & \dots & a_{2m_2}^1 & x & \dots & x \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots & x \\ a_{i1}^1 & a_{i2}^1 & \dots & \dots & \dots & \dots & \dots & a_{im_i}^1 \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots & x \\ a_{n1}^1 & a_{n2}^1 & \dots & a_{nm_n}^1 & x & x & \dots & x \end{bmatrix},$$

где x обозначает отсутствие компоненты. Индекс столбца указывает на шаг извлечения компоненты, а индекс строки — ветвь, из которой эта компонента извлечена. Обработку данных, заданных матрицей A_1 , на втором уровне отобразим с помощью операции транспонирования T (исходную матрицу на вто-

ром уровне представим $A_1^T = T(A_1)$). После выполнения операции транспонирования индекс строки указывает на номер шага для извлечения компоненты.

На втором уровне обработки (втором уровне ПИ сети) преобразование G организовано так, что дает возможность исследовать корреляцию между компонентами, которые были одновременно извлечены из различных ветвей первого уровня. Эта процедура применяется к строкам матрицы A_1^T :

$$A_2 = G(A_1^T) = G(T(G(M))) = \begin{bmatrix} a_{11}^2 & a_{12}^2 & \dots & \dots & a_{1m_1^2}^2 & x & \dots & x \\ a_{21}^2 & a_{22}^2 & \dots & a_{2m_2^2}^2 & x & x & \dots & x \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots & x \\ a_{i1}^2 & a_{i2}^2 & \dots & \dots & \dots & \dots & \dots & a_{im^2}^2 \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots & x \\ a_{n^2 1}^2 & a_{n^2 2}^2 & \dots & a_{n^2 m_n^2}^2 & x & x & \dots & x \end{bmatrix},$$

где $n^2 = m^1$, m^2 соответственно обозначено число параллельных ветвей и номер шага обработки на втором уровне.

Матрица A_2 формируется на втором уровне обработки (втором уровне ПИ сети) после выполнения временной декомпозиции, при которой каждая компонента a_{ij}^2 извлекается на шаге $t = i + j^* - 1$. Аналогичную процедуру обработки можно применить на всех последующих уровнях иерархии. Эта процедура реализована как горизонтальное выравнивание строк матрицы A_2 и располагает первый непустой элемент в каждой строке на главной диагонали. Результирующая матрица обозначена A_2^\bullet , $A_2^\bullet = P(A_2)$, где P — оператор сдвига строки:

$$A_2^\bullet = \begin{bmatrix} a_{11}^2 & a_{12}^2 & \dots & \dots & \dots & a_{1m_1^2}^2 & x & \dots & \dots & \dots & \dots & x \\ x & a_{21}^2 & a_{22}^2 & \dots & a_{2m_2^2}^2 & x & x & \dots & \dots & \dots & \dots & x \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & x \\ x & x & x & a_{i1}^2 & a_{i2}^2 & \dots & \dots & \dots & \dots & \dots & \dots & a_{im^2}^2 \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & x \\ x & x & x & x & x & a_{n^2 1}^2 & a_{n^2 2}^2 & \dots & a_{n^2 m_n^2}^2 & x & \dots & x \end{bmatrix}.$$

Компонента a_{11}^2 — единственная и поэтому ее можно извлечь на первом шаге обработки второго уровня, она не связана во времени с другими компонентами второго уровня и поэтому является выходной (первым хвостовым элементом ПИ сети). Кроме того, эта компонента — промежуточный результат сетевой обработки и единственная, извлеченная в результате многоступенчатой обработки на втором уровне. Она получается из матрицы путем удаления ее первого столбца, а оставшиеся компоненты сохраняются в матрице $A_2^{\bullet\bullet}$. Эта процедура выполняется путем применения оператора L , т.е. $L(A_2^\bullet) = a_{11}^2 + A_2^{\bullet\bullet}$. Матрица третьего уровня A_2^T получается после выполнения операции транспонирования T матрицы $A_2^{\bullet\bullet}$, которую можно записать в следующем виде: $A_2^T = T(L(P(A_2)))$.

Описанная процедура выполняется на каждом последующем иерархическом уровне до последнего уровня k_{\max} , в котором матрица $A_{k_{\max}}$ содержит одиноч-

ный элемент. Тогда $T(L(P(A_{k_{\max}}))) = \emptyset$. Последовательное использование операторов G, P, L, T можно представить как выполнение оператора $F : F(A_k^T) = T(L(P(G(A_k^T)))) = A_{k+1}^T$, а последовательное применение оператора F — как $F^k(A_1^T) = F^{k-1}[F(A_1^T)]$. Тогда весь многоуровневый процесс можно представить в следующей операторной форме:

$$F^{k_{\max}-1} \left[T \left(G \left(\bigcup_{i=1}^n M_i \right) \right) \right] = \{ a_{11}^k \mid k = 2, 3, \dots, k_{\max} \}. \quad (2)$$

Таким образом, результат обработки в ПИ сети представляется как вектор образа.

Воспользуемся общей идеей популяционного кодирования [17], построив модель какого-либо конечного действия, совершаемого по всем текущим действиям (конечное действие состоит из последовательности текущих действий). Так, например, конечное действие в виде зрительной саккады состоит из последовательности текущих микросаккад [18]. На уровне ветвей нейронной сети данное конечное действие при реализации популяционного кодирования соответствует усредненным параметрам этой сети [17]. Для ПИ сети усредненными параметрами являются количество элементов в ветви каждого уровня, которые определяются на основе модели вида (1), и значения самого элемента. В этом случае текущий распознаваемый образ будет отображаться текущей ПИ сетью и сравниваться с эталонной ПИ сетью с усредненными параметрами. (ПИ сеть с усредненными параметрами формирует эталонную сеть эталонного образа.)

Обозначив $\bar{a}_{i,j}^1$ среднее значение произвольного элемента первого уровня, $\bar{a}_{i,j}^2$ — второго уровня, $\bar{a}_{i,j}^3$ — третьего уровня, $\bar{a}_{i,j}^k$ — k -го, последнего, уровня, а также $N_{\bar{a}_{i,j}^1}$ — среднее число элементов первого уровня, $N_{\bar{a}_{i,j}^2}$ — второго уровня, $N_{\bar{a}_{i,j}^3}$ — третьего уровня и $N_{\bar{a}_{i,j}^k}$ — k -го уровня, можно сформировать ПИ сеть с усредненными параметрами (см. рис. 1) согласно идее популяционного кодирования. Среднее число элементов произвольного уровня вычисляется следующим образом:

$$\bar{a}_{i,j}^k = \frac{\sum a_{i,j}^k}{N_{\bar{a}_{i,j}^k}}.$$

Текущий или исследуемый образ, обработанный ПИ сетью с текущими параметрами $a_{i,j}^1, a_{i,j}^2, a_{i,j}^3, \dots, a_{i,j}^k$ и соответствующим числом элементов в ветвях каждого уровня $N_{a_{i,j}^1}, N_{a_{i,j}^2}, N_{a_{i,j}^3}, \dots, N_{a_{i,j}^k}$ сравнивается с эталонным образом, обработанным ПИ сетью с усредненными параметрами $\bar{a}_{i,j}^1, \bar{a}_{i,j}^2, \bar{a}_{i,j}^3, \dots, \bar{a}_{i,j}^k$ и средним числом элементов в ветвях соответствующего уровня $N_{\bar{a}_{i,j}^1}, N_{\bar{a}_{i,j}^2}, N_{\bar{a}_{i,j}^3}, \dots, N_{\bar{a}_{i,j}^k}$. Текущие параметры ПИ сети $a_{i,j}^1, a_{i,j}^2, a_{i,j}^3, \dots, a_{i,j}^k$ вычисляются в ее ветвях по формуле (1).

Если воспользоваться препарированием, т.е. адаптивным пороговым преобразованием с вычисляемым порогом с применением формулы для контурного препарирования элементов ПИ сети для каждого уровня [17] так, как это описано в [19], то от усредненных параметров $\bar{a}_{i,j}^1, \bar{a}_{i,j}^2, \bar{a}_{i,j}^3, \dots, \bar{a}_{i,j}^k$ можно перейти на основе трехуровневого кодирования к их отображению тернарными препаратами $(-1, 0, +1)$. Затем

определяются массивы разностей элемента со средним значением яркостей элементов разложения образа (или его фрагмента), в котором находится элемент изображения.

Для произвольного усредненного параметра тернарный переход может отображаться тремя видами препаратов: $a_{i,j}^0$ — нулевым, $a_{i,j}^1$ — положительным, $a_{i,j}^{-1}$ — отрицательным или $a_{i,j}^{()}$ — в общем виде. В этом случае ПИ сеть с числовыми отсчетами преобразуется в ПИ сеть с отсчетами $a_{i,j}^0, a_{i,j}^1, a_{i,j}^{-1}$ [14]. Эту процедуру тернарного преобразования можно описать в следующем виде:

$$R_{i,j} = a_{i,j}^k - \bar{a}_{i,j}^k.$$

Для препарирования образа полученная разность сравнивается с вычисляемым порогом δ , т.е.

$$a_{i,j}^{()} = \begin{cases} 1, & \text{если } R_{i,j} > \delta, \\ -1, & \text{если } R_{i,j} < -\delta, \\ 0, & \text{если } |R_{i,j}| \leq \delta. \end{cases} \quad (3)$$

Причем порог δ вычисляется из условия

$$N_t^{(1)} \cdot N_t^{(-1)} \cdot N_t^{(0)} = \max, \quad (4)$$

где $N_t^{(1)}, N_t^{(-1)}, N_t^{(0)}$ — количество единичных, минус единичных и нулевых препаратов для каждого порога t соответственно. При выполнении условия (4) справедливо соотношение $N_t^{(1)} \approx N_t^{(-1)} \approx N_t^{(0)}$.

В отличие от пороговой передаточной функции нейрона для известных нейронных сетей [16] для пороговой функции (3) при реализации ПИ сети порог не задается как некоторая постоянная величина, а является функцией от числа положительных, отрицательных, нулевых препаратов и вычисляется с помощью формулы (4).

Таким образом, пороговое адаптивное преобразование необходимо для того, чтобы при формировании тернарных препаратов сравнение текущих и усредненных элементов изображения по формуле (3) проводилось не на уровне шумовых сигналов, т.е. с нулем, а для каждого изображения вычислялся свой порог δ , который адаптировался бы к конкретному изображению, тем самым повышая помехоустойчивость преобразования.

При таком преобразовании существенно упрощается процедура корреляционного сравнения отсчетов текущей и эталонной ПИ сетей, так как данное сравнение выполняется не над полутоновыми отсчетами, а над простыми тернарными препаратами (0, +1, -1).

Для формирования эталонов изображения необходимо провести обучение по выборке. Для этого следует делать усреднение в ветвях каждого уровня, т.е. формировать усредненные элементы $\bar{a}_{i,j}^1, \bar{a}_{i,j}^2, \bar{a}_{i,j}^3, \dots, \bar{a}_{i,j}^k$, а затем перейти к тернарным препаратам $a_{i,j}^0, a_{i,j}^1, a_{i,j}^{-1}$. Выполнив указанные выше действия, сформируем ПИ сеть с эталонными параметрами для текущих изображений. После этого найдем коэффициент корреляции с ПИ сетью, которая использует текущие параметры (имеется в виду ПИ сеть с текущими значениями ее элементов $a_{i,j}^1, a_{i,j}^2, a_{i,j}^3, \dots, a_{i,j}^k$ с переходом к тернарным препаратам $a_{i,j}^0, a_{i,j}^1, a_{i,j}^{-1}$ и текущим числом элементов в ветвях каждого уровня $N_{a_{i,j}^1}, N_{a_{i,j}^2}, N_{a_{i,j}^3}, \dots, N_{a_{i,j}^k}$).

Анализ данных, для которых существенна последовательность, проводится с использованием хронологических (временных) рядов. Каждый временной ряд

состоит из периодов или моментов времени t , которым соответствуют уровни ряда. В качестве статистических показателей в данном методе используются координаты энергетических центров изображений пятен лазерных пучков [21, 22].

СГЛАЖИВАНИЕ ЭМПИРИЧЕСКИХ ДАННЫХ ПО ГИПЕРБОЛЕ

Из анализа методов сглаживания эмпирических данных, проведенного в [20], видно, что независимо от метода сглаживания и способа определения линии тренда происходит одинаковое распределение «пиков» и «ям». Для второй стадии статистического исследования, т.е. статистической сводки и группирования первичных данных, будет использоваться метод сглаживания по гиперболе, описанный далее.

Выявление основной тенденции (тренда) ряда является одним из главных методов анализа и обобщения временных рядов. Линия тренда временного ряда указывает на изменение исследуемого явления во времени без определенных отклонений, вызванных различными факторами. Тенденцию развития явлений во времени можно найти в соответствии с методами увеличения интервалов, скользящей средней и аналитического сглаживания [23].

Уровни временного ряда рассмотрим как функцию времени $\hat{Y}_t = f(t)$. Задача сглаживания сводится к нахождению такого вида функции, ординаты точек которой являются ближайшими к значениям фактического временного ряда.

Самыми распространенными закономерностями, описывающими тенденцию развития явлений, являются: прямая, показательная функция, парабола второго и третьего порядков, гипербола, логистическая функция, экспонента, ряд Фурье и др. Анализ показывает, что наиболее целесообразно использовать метод сглаживания по гиперболе, поскольку именно она наиболее точно описывает рост или спад временного ряда. Данный метод сглаживания по сравнению с другими менее трудоемкий [10, 23].

Уравнение гиперболы можно записать в виде $\hat{Y}_t = a_0 + a_1 / t$, где a_0, a_1 — параметры уравнения гиперболы, для нахождения которых методом наименьших квадратов необходимо применить систему нормальных уравнений

$$\begin{cases} \sum_{i=1}^n Y_i = na_0 + \sum_{i=1}^n \frac{a_1}{t_i}, \\ \sum_{i=1}^n Y_i \frac{1}{t_i} = a_0 \sum_{i=1}^n \frac{1}{t_i} + a_1 \sum_{i=1}^n \frac{1}{t_i^2}. \end{cases} \quad (5)$$

Из системы (5) несложно находятя параметры уравнения гиперболы a_0, a_1 :

$$\lg a_0 = \frac{\sum_{i=1}^n \lg Y_i}{n}, \quad \lg a_1 = \frac{\sum_{i=1}^n t_i \lg Y_i}{\sum_{i=1}^n t_i^2}.$$

Если выполнить аппроксимацию сглаженного ряда на N шагов вперед, то можно осуществить прогноз тренда также на несколько шагов вперед. Качественные показатели прогнозирования (средняя и максимальная ошибки) находятся путем экспериментального определения оптимального шага дискретизации и количества шагов прогнозирования.

Исходя из заданий контроля параметров пучка лазерного излучения, используем векторы \bar{X} и \bar{Y} с координатами X и Y энергетических центров фрагментов трасс в качестве основных показателей для распознавания изображений пятен лазерных пучков и прогнозирования. Коэффициенты корреляции на первом, среднем, предпоследнем и третьем с конца уровнях ПИ сети будут вспомо-

гательными при применении метода обучения ПИ сети для распознавания динамических образов.

КОМБИНИРОВАННЫЙ МЕТОД ОБУЧЕНИЯ

Рассмотрим последовательность комбинированного метода обучения, основанную на коррекции ошибок и на использовании памяти ПИ сети при распознавании образов:

- построение структуры ПИ сети выбранного образа (изображения пятна пучка лазерной трассы);
- применение метода обучения, основанного на использовании памяти (классификатором на основе k -ближайших соседей является число уровней ПИ сети);
- построение эталонной структуры ПИ сети для эталонного образа;
- применение метода обучения, основанного на коррекции ошибок (критерием верификации является коэффициент корреляции матриц эталонной и текущей ПИ сетей на нулевом уровне);
- коррекция ошибок для коэффициентов корреляции проводится на нулевом, первом, среднем, предпоследнем и третьем с конца уровнях ПИ сети (многочисленные эксперименты показали, что именно эти параметры наиболее значимы для корреляционного сравнения).

Число уровней ПИ сети определяется длиной алгоритма L . Последняя и соответственно число блоков в структуре ПИ сети (см. рис. 1) вычисляются следующим образом:

$$L = R^1 + \sum_{j^*=1}^k P^{j^*+1} - (n^{j^*} - 1),$$

где $P^{j^*} = \max \{R_1^{j^*}, R_2^{j^*} + 1; R_3^{j^*} + 2; \dots; R_{n^{j^*-1}}^{j^*} + n^{j^*-1} - 1\}$; n^{j^*-1} — количество элементов множества на уровне $j^* - 1$, переходящие на j^* -й уровень для дальнейшего преобразования; $R_{n^{j^*-1}}^{j^*}$ — количество элементов на j^* -м уровне. Коррек-

ция проводится до тех пор, пока вспомогательные параметры сети придут к равновесному состоянию (+1) или превысят его. Если значение параметров приводит к неравновесному состоянию (-1), значит, текущий образ не эталонный.

Параметрами сети являются массивы с координатами X и Y на определенном временном промежутке, который определяется количеством шагов прогнозирования, а также параметры уравнения гиперболы a_0, a_1 на данном промежутке. Коэффициенты корреляции на первом, среднем, предпоследнем и третьем с конца уровнях ПИ сети — вспомогательные параметры при использовании метода обучения ПИ сети для распознавания динамических образов.

Структурная схема разработанного метода прогнозирования с применением ПИ сети показана на рис. 2. На вход системы поступают массивы данных с координатами X и Y на определенном временном промежутке. Далее эти данные поступают в блок определения параметров гиперболы, где вычисляются параметры уравнения гиперболы a_0, a_1 . Обработка в ПИ сети входных данных проводится на основе реализации преобразований вида (1) и (2). В базе данных сохраняются следующие вспомогательные параметры: коэффициент корреляции матриц эталонной и текущей ПИ сетей на нулевом уровне, а также коэффициенты корреляции на нулевом, первом, среднем, предпоследнем и третьем с конца уровнях ПИ сети. Параметры гиперболы поступают в систему прогнозирования параметров трассы, где определяется положение по осям X и Y следующего фрагмента трассы.

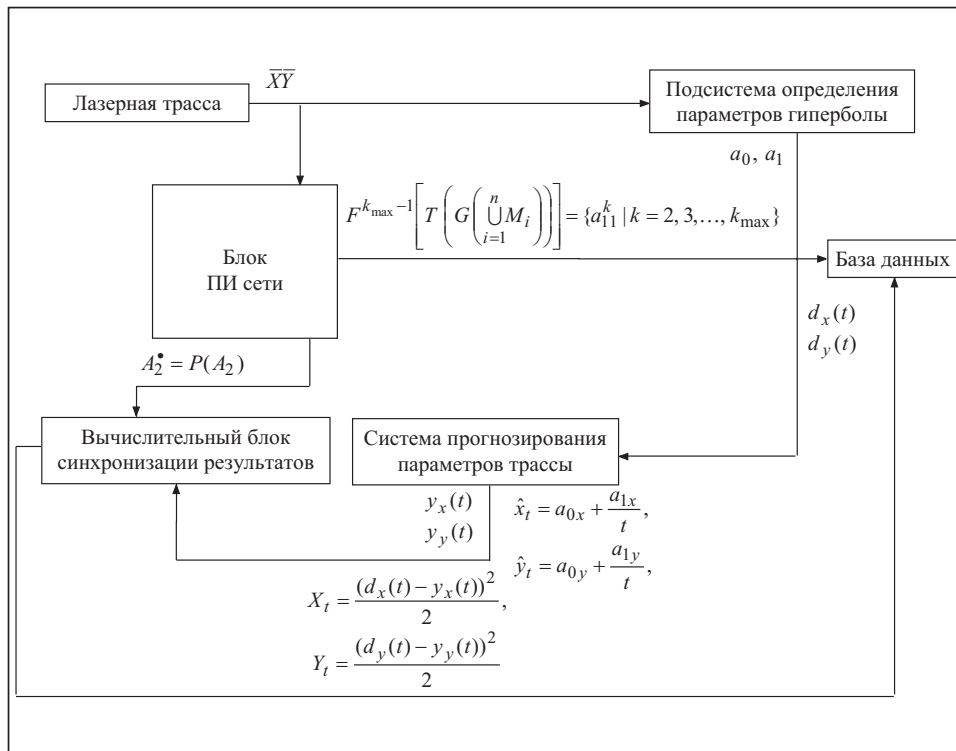


Рис. 2. Структурная схема разработанного метода прогнозирования с применением ПИ сети

В блоке синхронизации результатов проводятся следующие операции. Обработанные в ПИ сети данные поступают в базу данных, где осуществляется выборка наиболее похожих данных при сравнении со вспомогательными параметрами ПИ сети. После этого над выбранными из базы данными и выходными данными ПИ сети проводится операция коррекции ошибки. Скорректированные данные обновляют запись вспомогательных параметров в базе данных, где сохраняется результат прогнозирования. Процесс происходит рекурсивно, начиная с первого и заканчивая последним фрагментом трассы.

Таким образом, результат прогнозирования положения энергетических центров изображений пятен лазерных пучков формируется посредством преобразования параметров уравнения гиперболы и обработки фрагментов трассы в ПИ сети с использованием ее вспомогательных параметров.

ПРОГРАММНАЯ РЕАЛИЗАЦИЯ ПАРАЛЛЕЛЬНО-ИЕРАРХИЧЕСКОЙ СЕТИ ДЛЯ ПРОГНОЗИРОВАНИЯ ПОЛОЖЕНИЯ ЭНЕРГЕТИЧЕСКИХ ЦЕНТРОВ ИЗОБРАЖЕНИЙ ПЯТЕН ЛАЗЕРНЫХ ПУЧКОВ

Для предложенного метода прогнозирования и точного измерения положения энергетических центров изображений пятен лазерных пучков путем определения центра тяжести разработано программное обеспечение.

Для начала работы с изображениями лазерной трассы ее файл необходимо открыть через диалоговое окно выбора файла трассы. Разработанное программное средство содержит окно для иллюстрации динамики движения пятен лазерных пучков по осям X и Y , график прогноза их движения, а также следующие информационные блоки:

- 1) информация о видеотрассе;
- 2) определение центра тяжести (энергетических центров пятенных образов лазерной трассы);
- 3) статистические параметры;
- 4) прогнозирование.

После загрузки файла трассы информационный блок 1 автоматически заполняется информацией о количестве кадров, содержащихся в трассе, ширине и высоте кадра (в пикселях), глубине цвета (в битах), количестве кадров (в секунду). Также автоматически заполняется информационный блок 3 информацией о минимальных и максимальных значениях координат по осям X и Y соответственно, а также о среднем значении координат и среднем квадратичном отклонении координат по всей трассе по осям X и Y .

В информационном блоке 2 вычисление центра тяжести происходит динамически в реальном времени при работе с файлом при фиксации следующих параметров:

- положение энергетического центра пучка по осям X и Y в пикселях с точностью до третьего знака после запятой;
- отклонение энергетического центра пучка по осям X и Y от средних значений в пикселях с точностью до третьего знака после запятой;
- номер кадра.

Информационный блок 4 программной реализации (прогнозирование) предназначен для прогнозирования координат местоположения энергетических центров лазерных трасс и регулирования следующих параметров прогнозирования:

- шаг дискретизации;
- количество шагов, которые необходимо спрогнозировать;
- значение точности, которое будет учитываться при прогнозировании.

РЕЗУЛЬТАТЫ ЭКСПЕРИМЕНТАЛЬНЫХ ИССЛЕДОВАНИЙ

Для проверки эффективности работы разработанной программной реализации проводились эксперименты над образами пятен лазерных трасс. Основные результаты получены с использованием базы данных лазерных трасс, предоставленных НПО «Астрофизика» и ЗАО «Космические информационно-аналитические системы» (Москва, РФ), где внедрялись полученные практические результаты работы.

Базы содержат последовательности кадров пятен лазерных пучков, которые формируют отдельные трассы, состоящие из фрагментов (как правило, от двух до пяти тысяч), полученных от приемного устройства с периодичностью 40 мс. Каждое изображение образа имеет размерность 128×128 э.р.

Для проверки разработанного метода и определения эффективности его работы проводились эксперименты по прогнозированию на один шаг положения энергетических центров изображений лазерных пучков на основе известных нейронных сетей. Эксперименты промоделированы в программе STATISTICA 6.0 [25]. Максимальная относительная погрешность $\delta_{x \max}$ меньше при использовании нейронных сетей, поэтому они более предпочтительны для применения по сравнению с численными методами [10].

Результаты экспериментальных исследований по прогнозированию временных рядов приведены в табл. 1.

Погрешности вычислялись следующим образом:

$$\delta_{\text{ср}} = \frac{\sum_{i=1}^N |(X_{\text{прогн}} - X_{\text{тек}}) / X_{\text{тек}}|}{N} \cdot 100 \%,$$

$$\delta_{\text{max}} = \max (|(X_{\text{прогн}} - X_{\text{тек}}) / X_{\text{тек}}|),$$

где $X_{\text{прогн}}$, $X_{\text{тек}}$ — спрогнозированное и текущее значения координат соответственно.

Исследования многочисленных примеров подтверждают целесообразность применения разработанного метода для задач корреляционного сравнения и прогнозирования характеристик изображений, в частности в задачах идентификации

изображений для систем профилирования лазерных лучей (исследовано 10 видеотрасс по 2044 изображениях пятен лазерных пучков в каждой).

Из проведенных исследований видно, что средняя погрешность прогнозирования с применением различных типов нейронных сетей практически одинакова и составляет 1,62 %. Максимальное значение погрешности прогнозирования с применением разных типов нейронных сетей колеблется в пределах от 4,74 до 5,81 %.

На рис. 3 и рис. 4 приведены графики, полученные при прогнозировании временных рядов лазерных трасс с координатами X и Y с помощью разработанной программной реализации с применением ПИ сети. Соответствующие (см. табл. 1) показатели составили: 0,552 % — средняя погрешность прогнозирования; 1,23 % — максимальное значение погрешности прогнозирования.

Таблица 1

Тип нейронной сети	Средняя ошибка прогнозирования, %	Максимальное значение ошибки прогнозирования, %
РБФ S1	1,63	5,81
Линейная S5	1,63	4,74
Линейная S3	1,63	4,75
МП 5-8-4	1,63	5,04
МП 5-5-4	1,63	5,04
ПИ	0,55	1,23




Рис. 3. Выполнение прогнозирования с использованием ПИ сети: 1 — текущие координаты, 2 — прогноз



Рис. 4. Выполнение прогнозирования с помощью нейроподобной ПИ сети (увеличенный фрагмент): 1 — ряд X , 2 — прогноз ряда X

ЗАКЛЮЧЕНИЕ

В настоящей статье разработан метод прогнозирования с использованием ПИ сети и комбинированного метода обучения со сглаживанием эмпирических данных по гиперболе. При выполнении определенной аппроксимации сглаженного ряда осуществлен прогноз тренда на несколько шагов вперед. Качественные показатели прогнозирования (средняя и максимальная ошибки) найдены путем экспериментального определения оптимального шага дискретизации и количества шагов прогнозирования.

Для автоматизации процесса прогнозирования и точного измерения координат положения энергетических центров пятен лазерных пучков в реальном времени разработано программно-техническое средство, содержащее окно для иллюстрации динамики движения пятен лазерных пучков по осям X и Y , а также график прогноза движения лазерных пучков по указанным осям. Вычисление центра тяжести изображений пятен лазерных пучков происходит динамически в реальном времени.

Для проверки разработанного метода и определения эффективности его работы проведены эксперименты по сравнительной оценке прогнозирования на основе известных нейронных сетей и предложенного метода с использованием ПИ сети. Из результатов экспериментальных исследований видно, что средняя погрешность прогнозирования с применением разных типов нейронных сетей практически одинакова и составляет 1,62 %. А максимальное значение погрешности прогнозирования с применением разных типов известных нейронных сетей колеблется в пределах от 4,74 до 5,81 %.

Соответствующие показатели прогнозирования с применением ПИ сети составили: средняя погрешность прогнозирования — 0,552 %; максимальное значение погрешности прогнозирования — 1,23 %.

Результаты экспериментов подтверждают, что разработанный метод прогнозирования положения энергетических центров пятен лазерных пучков с использованием ПИ сети по сравнению с известными структурами нейронных сетей, выполняющими такое же прогнозирование, более эффективен и имеет существенно меньшие среднюю и максимальную погрешности прогнозирования для систем реального времени.

СПИСОК ЛИТЕРАТУРЫ

1. Елисеев И.И., Костеева Т.В., Хоменко Л.М. Международная статистика. — Минск: Высш. шк., 1995. — 224 с.
2. Shealy D.L., Hoffnagle J.A. Laser beam shaping profiles and propagation // *J. Applied Optics*. — 2006. — **45**, N 21. — P. 5118–5131. — <http://dx.doi.org/10.1364/AO.45.005118>.
3. Roundy C.B. The importance of beam profile // *Physics World*. — 1990, July. — P. 65–66.
4. Абдрахманов К.Ш., Быкова О.Г., Улановский М.В. Стандартизация методов измерений ширин, углов расходимости и коэффициентов распространения пучков лазерного излучения (Измерение расходимости лазерного пучка) // *Метрология*. — 2010. — № 2. — С. 23–44.
5. Быкова А.Г., Либерман А.А., Улановский М.В. Стандартизованные методики измерений мощности, энергии и временных характеристик лазерного пучка // Там же. — 2009. — № 12. — С. 15–30.
6. Demelonne optical inter-orbit communications engineering test satellite (OICETS) / Y. Fujiwara, M. Mokuno, T. Jono et al. // *Acta Astronaut.* — 2007. — N 61. — P. 163–175.
7. Garcia-Zambrana A., Castillo-Vazquez C., Castillo-Vazquez B. Space-time trellis coding with transmit laser selection for FSO links over strong atmospheric turbulence channels // *Optics Express*. 2010. — **18**, N 6. — P. 5356–5366. — <http://dx.doi.org/10.1364/OE.18.005356>.

8. Orlov D.A., Neverova E.A. Determination of the position of the center of a laser beam when the dynamic range of the matrix receiver is exceeded // *Measurement Techniques*. — 2011. — **53**, N 10. — P. 1140–1146.
9. Четыркин Е.М. Статистические методы прогнозирования. — М.: Статистика, 1987. — 200 с.
10. Method of reference tunnel formation for improving forecast results of the laser beams spot images behavior / L. Timchenko, A. Poplavskyy, N. Petrovskiy et al. // *J. Opt. Eng.* — 2011. — **50**. — P. 1–8.
11. Ghiassi M., Saidane H., Zimbra D.K. A dynamic artificial neural network model for forecasting time series events // *Intern. J. Forecasting*. — 2005. — **21**, N 2. — P. 341–362.
12. Zhang G., Patuwo B.E., Hu M.Y. Forecasting with artificial neural networks: The state of the art // *Ibid.* — 1998. — **14**, N 1. — P. 35–62.
13. Hill T., Marquez L., M. O'Connor W. Remus Artificial neural network models for forecasting and decision making // *Ibid.* — 1994. — **10**, N 1. — P. 5–15.
14. Тимченко Л.И. Многоэтапная параллельно-иерархическая сеть как модель нейроподобной схемы вычислений // *Кибернетика и системный анализ*. — 2000. — № 2. — С. 114–134.
15. Свечников С.В., Кожемяко В.П., Тимченко Л.И. Квазиимпульсно-потенциальные оптоэлектронные элементы и устройства логико-временного типа. — К.: Наук. думка, 1987. — 256 с.
16. Haykin S. *Neural networks and learning machines* (3rd Edition). — Englewood Cliffs (N.J.): Prentice Hall, 2008. — 1104 p.
17. Method for training of a parallel-hierarchical network, based on population coding for processing of extended laser paths images / L.I. Timchenko, Yu.F. Kутаev, V.P. Kozhemyako et al. // *Proc. of SPIE*. — 2002. — **4790**. — P. 465–479.
18. Тимченко Л.И. Конвергентні та дивергентні процеси в реальних та штучних нейронних мережах // *Вісн. ВПІ*. — 1997. — № 1. — С. 5–10.
19. Сегментація напівтонових зображень за ознакою зв'язаності / А.Л. Железняк, Л.І. Тимченко, О.І. Стасюк та ін. — К.: ДЕДУТ, 2008. — 144 с.
20. Теорія статистики / П.Г. Вашків, П.І. Пастер, В.П. Сторожук та ін. — К.: Либідь, 2001. — 320 с.
21. Применение параллельно-иерархического метода распознавания изображений пятен лазерных пучков / Л.И. Тимченко, В.В. Мельников, Н.И. Кокряцкая и др. // *Тр. Междунар. науч.-техн. конф. «Многопроцессорные вычислительные и управляющие системы – 2009»*. — Таганрог, 2009. — С. 147–150.
22. Метод знаходження енергетичних центрів фрагментів лазерних протяжних трас в реальному масштабі часу для розпізнавання образів / Л.І. Тимченко, В.В. Мельніков, Н.І. Кокряцка та ін. // *Пр. 9-ї всеукр. міжнар. конф. «Оброблення сигналів і зображень та розпізнавання образів»*. — Київ, 2008. — С. 213–216.
23. Копрен У. Методы выборочного исследования. — М.: Статистика, 1976. — 440 с.
24. Метод организации параллельно-иерархической сети для распознавания образов / Л.И. Тимченко, В.В. Мельников, Н.И. Кокряцкая, Ю.Ф. Кутаев // *Кибернетика и системный анализ*. — 2011. — № 1. — С. 152–163.
25. Боровиков В.П. *STATISTICA*. Искусство анализа данных на компьютере. — СПб.: Питер, 2003. — 688 с.

Поступила 03.10.2011