

УДК 681.327

*А.А. Дудкин*Объединенный институт проблем информатики НАН Беларуси, г. Минск, Беларусь
doudkin@newman.bas-net.by

Нейросетевая технология распознавания объектов топологии интегральных микросхем

Рассмотрены методы обработки изображений и распознавания на основе нейронных сетей, ориентированные на применение в системах технического зрения проектирования интегральных микросхем. Представлена структура системы, реализующей нейросетевую технологию распознавания объектов топологии интегральных микросхем.

Введение

Общая тенденция к повышению уровня интеграции электронных приборов приводит к уменьшению геометрических размеров электронных компонент. Далее повышение сложности электронной продукции и улучшение потребительских свойств самого изделия приводят к тому, что стремительно растет плотность монтажа на печатных платах (ПП), на которых эти компоненты размещаются. Одновременно возрастает и сложность процесса сборки: зачастую в процессе сборочного производства применяются двусторонний поверхностный монтаж, ручная установка компонентов, специальные виды пайки и механической сборки. И хотя производители стремятся к совершенствованию технологии сборки, очень часто бывает трудно уменьшить количество дефектов на схему или плату, поскольку при возрастании сложности изделия и технологии его изготовления катастрофически увеличивается и количество возможных ошибок. Поэтому контроль топологии интегральных микросхем (ИС) и ПП является составной частью жизненного цикла изделия.

Сложность объекта контроля диктует необходимость использования различных видов контроля: внутрисхемного, оптического и рентгеновского. Оптимальная тестовая стратегия чаще всего реализуется на основе комбинированного подхода, обеспечивающего баланс между такими требованиями, как тестовое покрытие, выявляемость дефектов, доступ, время внедрения тестирования, время безотказной работы, общая экономия средств и производительность. Однако тенденция такова, что процент схем с тестовым доступом уменьшается. Данное обстоятельство делает актуальным бесконтактное тестирование; в частности, возрастает роль оптического контроля в процессе разработки и изготовлении как ИС, так и ПП. Исходными данными для контроля является изображение топологии и описание топологического чертежа, на основании которого с помощью генератора (мультипликатора) это изображение формируется на поверхности фоторезиста или ПП. Вследствие различного рода эффектов и явлений, сопровождающих процесс мультиплицирования, результирующее изображение не является точной масштабированной копией оригинала.

Искажения вносятся на каждом этапе прохождения данных от оптических устройств до устройств их обработки. При этом наиболее существенные искажения в результирующее изображение вносятся оптическим объективом. В частности, имеют место геометрические искажения с центральной симметрией, обусловленные конструк-

тивными особенностями самого объектива, а также способом его монтировки. Другой тип искажений связан с конструкцией объектива и проявляется в том, что изображение как бы подвергается фильтрации низкочастотным фильтром. Еще один тип искажений как формы, так и размеров – эффект оптической близости – проявляется при воспроизведении структурных элементов, размеры которых соизмеримы с длиной волны излучения генератора топологии. Помимо оптических искажений имеют место искажения ввода сгенерированного изображения.

При автоматизированном определении дефектов на изображениях топологии ИС требуется по некоторым признакам выделять (идентифицировать, распознать) некоторые однородные области изображения, причем, как правило, подобие нечеткое и часто нарушается. Если образы сильно искажены, то становится слишком трудоемким выделение информативных признаков для эффективной классификации. Этапы предварительной обработки изображения, например фильтрация, сглаживание и скелетизация, позволяют уменьшить влияние искажений на процесс распознавания [1-3]. Тем не менее, при обработке визуальной информации в различных предметных областях имеет место задача распознавания в условиях неполной и нечеткой информации. Наиболее подходят для ее решения нейросетевые технологии. Нейронная сеть (НС) при этом выступает в роли классификатора. Применение в задачах обработки визуальной информации обосновывается также свойством обучаемости или адаптивности НС к новым задачам, при этом сохраняются архитектура сети и алгоритм ее функционирования. Это, в свою очередь, позволяет использовать одну и ту же модель в различных задачах.

Существует ряд НС, позволяющих решать задачу распознавания образов с определенной степенью точности [4-7]: многослойный перцептрон, сеть радиальной базисной функции, сети АРТ, сети Хопфилда, самоорганизующееся отображение Кохонена. Наиболее подходящим для этой цели является неоконитрон [8], [9], который представляет собой многоуровневую НС, состоящую из каскадного соединения слоев нейронов. В основе его работы лежит принцип иерархической обработки, обеспечивающий извлечение инвариантных признаков [9-11]. При этом обработка обычно осуществляется в два этапа: сначала извлекаются признаки, затем достигается их инвариантность пространственным объединением. Для любого признака извлекается ряд значений с идентичными размерами рецепторных областей, но распределенными по входному слою. Это достигается путем разделения весовых коэффициентов между нейронами одного типа, выделяющими одинаковый признак. Объединение значений активностей соседних нейронов, чувствительных к одному и тому же локальному признаку в различных местоположениях, приводит к отклику на определенный признак, который инвариантен к местным изменениям.

Распознаваемый образ подается на входной слой НС и далее послойно обрабатывается последующими ее слоями, при этом нейроны на более глубокого слоя распознают более сложные признаки образа.

Для повышения точности иерархического распознавания и увеличения производительности НС исследования проводятся в следующих направлениях:

- Модификация правил выделения признаков за счет введения новых дополнительных инвариантов относительно искажений [12], [13].
- Модификация структуры и принципов послойной обработки НС [14].
- Разработка алгоритмов самообучения НС [15-18].

Таким образом, идея заключается в разработке нейросетевых алгоритмов для основных этапов обработки объектов топологии, критичных для принятия решения при распознавании. Концепция нейросетевой обработки и идентификации видеоизображений предполагает использование следующих подходов к обработке изображений топологических слоев ИС:

- 1) проблемно-ориентированной предварительной обработки, сохраняющей информационные признаки топологических объектов, что позволяет сократить число связей НС, упростить и ускорить процесс обучения;

2) выделения (идентификации) объекта на изображении для нейросетевой обработки за счет использования информации об иерархии признаков, что сокращает затраты времени на обработку (осуществляется поиск лишь в идентифицированной области);

3) использования набора классификаторов, в котором по результатам классификации на тестовой выборке производится выбор наилучшей модели классификатора для обработки всех изображений.

Как правило, эффективные методы предварительной обработки удается получить с учетом специфики изображения топологического слоя или ФШ. Поэтому предлагаемые методы существенно учитывают особенности изображений, а алгоритмы обработки слоя являются параметрически настраиваемыми, причем шаги каждого алгоритма также могут варьироваться. Основу обработки составляют быстрые алгоритмы вычисления дескрипторов в различных ортогональных базисах, алгоритмы фильтрации на основе преобразований Уолша, Хаара, Адамара и математической морфологии, которые описаны в [19], [20]. В данной же статье рассмотрена нейросетевая реализация второго и третьего подходов, а также представлена структура системы, реализующей нейросетевую технологию распознавания объектов топологии интегральных микросхем.

Выделение объекта на изображении

Выделение объектов на изображениях слоев – одна из основных задач, которая решается после выполнения сегментации. При производстве фотошаблонов и ИС для выделенных объектов контролируются конструкторско-технологические ограничения (КТО) и определяются их дефекты. Основные требования к алгоритму выделения объектов: высокая скорость при обработке больших изображений и низкий процент ошибок при работе с зашумленными изображениями, которые к тому же могут иметь разные уровни яркости. Существуют разные подходы к решению данного класса задач, которые имеют свои достоинства и недостатки. Так, корреляционные методы обладают относительно высокой вычислительной сложностью, к тому же их эффективность существенно снижается при увеличении уровня шумов на анализируемом изображении. Различные уровни яркости также негативно влияют на качество работы корреляционных методов. Алгоритмы, основанные на использовании геометрических признаков, менее чувствительны к вариациям яркости, однако очень чувствительны к уровню шумов. Использование моментных инвариантов осложняется высокой чувствительностью этих признаков даже к небольшим вариациям формы выделяемых объектов относительно эталонов. В общем случае получение моментных инвариантов связано с большими вычислительными затратами, хотя существуют быстрые алгоритмы, которые можно использовать при определенных условиях. Алгоритмы, основанные на использовании в качестве признаков моментных инвариантов, также теряют свою эффективность при увеличении количества шумов на анализируемом изображении. Алгоритм поиска элементов топологии на основе НС состоит из двух основных этапов:

- обучения НС;
- сканирования изображения окном, размер которого равен размеру обучающего изображения, и определения по отклику НС, является ли изображение внутри окна элементом.

Для поиска элементов топологии разработаны следующие НС: многослойный персептрон, самоорганизующиеся карты Кохонена, неоконитрон.

Многослойный персептрон состоит из множества слоев нейронных элементов, причем доказано, что достаточно трех слоев для создания сколь угодно сложной решающей граничной поверхности в пространстве обучающих образов. Соответственно такая сеть состоит из k нейронов входного слоя, i нейронов скрытого слоя и j нейронов выходного слоя, а также матриц связей $w_{k,i}$ и $w_{i,j}$. Каноническим методом

обучения такой сети считается алгоритм обратного распространения ошибки. При построении НС количество нейронов первого слоя определяется в соответствии с количеством параметров (информативных признаков): яркостных значений, семантических дескрипторов и рядом дополнительных, таких, как отношение периметра аппроксимирующей окружности к периметру сегмента; отношение площади фоновых объектов на сегменте к площади сегмента, образуемого внешним контуром, т.е. к такой площади сегмента, если бы на нем не было фоновых объектов; отношение длины выпуклой оболочки сегмента к длине внешнего периметра сегмента, характеризующее выпуклость границы сегмента. Количество нейронов второго слоя определяется эмпирически. Выходной слой имеет один нейрон, активность которого определяет принадлежность μ изображения окна к элементу в виде некоторой функции, значение которой сравнивается с некоторым заданным порогом.

НС с радиальной базисной функцией положительно отличается от сетей обратного распространения ошибки в том, что для данной сети не существует проблемы выбора количества скрытых нейронов, так как они определяются количеством групп (кластеров), на которые разбивается пространство обучающих образов при помощи радиальной базисной функции. Сеть на основе радиальной базисной функции состоит из трех слоев нейронов: входного, скрытого и выходного. Причем входной слой обучается на основе радиальной базисной функции, а выходной – на основе алгоритма обратного распространения ошибки. Скрытый слой нейронов полностью связан с линейным выходным слоем, функция активации которого определяется преобразованием Гаусса:

$$v_k = \exp\left(-\frac{I_k^2}{y^2}\right), \text{ где } I_k = \|X - C_k\| - \text{евклидово расстояние.}$$

Самоорганизующаяся НС Кохонена представляет собой сеть с прямыми связями. В качестве метода обучения используется конкурентное обучение. По мере поступления входных образов на такую сеть посредством обучения происходит разбиение n -мерного входного пространства на различные области решений, каждой из которых соответствует отдельный нейрон. Самоорганизация таких сетей осуществляется в результате топологического упорядочивания входной информации. При этом соседние наиболее похожие входные образы должны отображаться на соседние нейроны второго слоя. Такие сети функционируют по конкурентному принципу. В соответствии с ним выходное значение нейрона-победителя с номером k равняется единице, а для остальных нейронов равно нулю:

$$Y_j = F(S_j) = \begin{cases} 1, & \text{если } j = k; \\ 0, & \text{если } j \neq k. \end{cases}$$

Номер нейронного элемента-победителя может определяться в соответствии с минимальным евклидовым расстоянием между входным и весовым векторами:

$$D_j = |X - W_j| = \sqrt{(x_1 - w_{1j})^2 + (x_2 - w_{2j})^2 + \dots + (x_n - w_{nj})^2};$$

$$D_k = \min_j |X - W_j|.$$

Эффективность применения нейросетевого метода поиска объектов показана в сравнении с корреляционным методом. Входными данными для тестирования являлись полутоновые фрагменты фотоизображения поликремниевого слоя ИС. Производился поиск двух объектов (варианты 1 и 2). Результаты тестирования (табл. 1) показали, что метод формирования критерия схожести двух изображений с

помощью описанной НС является лучшим по сравнению с методом расчета корреляции этих двух изображений. Этот результат был достигнут вследствие того, что НС является инвариантной к искажениям формы и яркости изображения распознаваемого объекта, а также требует меньшего количества обучающих образцов для достижения необходимой точности.

Таблица 1 – Результаты тестирования

Объем обучающей выборки	Точность распознавания			
	Корреляционный метод		Нейронная сеть	
	Вариант 1	Вариант 2	Вариант 1	Вариант 2
1	63,1	67,4	87,0	89,0
3	72,3	73,6	96,3	97,0
6	81,4	84,2	98,5	99,0

Неокогнитрон содержит следующие элементы: R -слой, S -слои, C -слои, \bar{S} -подслои, \bar{C} -подслои, \tilde{S} -нейроны, \tilde{C} -нейроны, \check{S} -связи, \check{C} -связи. Архитектура НС показана на рис. 1, где R – это рецепторный слой, его нейроны отвечают за подачу входного изображения в НС; слои S и C обведены тонкой линией, их образуют \tilde{S} - и \tilde{C} -нейроны соответственно, которые выполняют функцию выделения на изображении таких признаков, как линии, углы, пересечения (они расположены в овалах); S - и C -слои делятся на \bar{S} - и \bar{C} -подслои (обведены жирной линией).

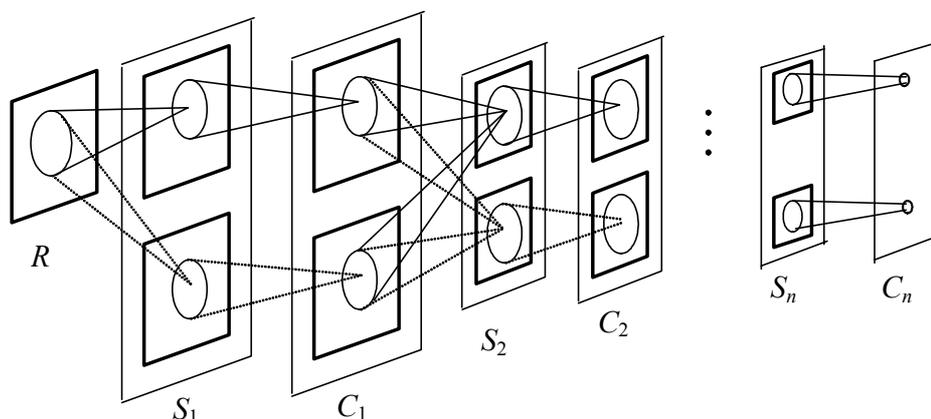


Рисунок 1 – Общая архитектура сети

\bar{S} -подслой состоит из \tilde{S} -нейронов, которые выделяют один и тот же признак изображения, например линию. Таким образом, \bar{S} -подслой образует своего рода карту этого признака в предыдущем слое.

\tilde{S} -нейроны имеют \check{S} -связи с модифицируемыми весовыми коэффициентами, которые принимают свои значения во время обучения подслоя. \check{S} -связи, идущие от одного \tilde{S} -нейрона, образуют в предыдущем слое рецепторное поле, которое можно разделить на P подгрупп в соответствии с количеством \bar{C} -подслоев в предыдущем слое, т.е. к каждому \bar{C} -подслою направлена своя подгруппа \check{S} -связей. Каждая подгруппа рецепторного поля характеризуется определенным размером и положением в предыдущем подслое. Размер подгруппы рецепторного поля соответствует размеру

выделяемого признака. Положение рецепторного поля определяется положением \tilde{S} -нейрона в \bar{S} -подслое, т.е. положение рецепторных полей для нейронов из одного \bar{S} -подслоя отличается только параллельным сдвигом относительно друг друга. Поскольку нейроны из одного \bar{S} -подслоя выделяют один и тот же признак, то можно обучить только один нейрон из этого подслоя и использовать его весовые коэффициенты для всех остальных нейронов.

\tilde{S} -нейрон обучается с помощью функции вычисления динамического среднего:

$$w(t+1) = w(t) + \frac{1}{t+1} \cdot [u(t+1) - w(t)],$$

где t – номер итерации обучения; w – значение весового коэффициента; u – значение активности нейрона на входе обучаемой связи. Функция активации \tilde{S} -нейрона соответствует радиальной базисной функции:

$$U_{Sl}(n, k) = \exp \left[\sqrt{\frac{\sum_{p=1}^{P_{Cl-1}} \sum_{v \in Al} (U_{Cl}(n+v, p) - \min_{\forall v} (U_{Cl}(n+v, p))) - w(v, k))^2}{N}} \right],$$

где l – порядковый номер слоя; k – номер обучаемой плоскости; n – двумерный индекс нейрона в k -й плоскости; w – весовой коэффициент связи; v – двухмерное смещение входной связи в подгруппе связей Al ; Al – двухмерная величина, характеризующая размер рецепторной подгруппы в предыдущем \bar{C} -подслое; N, p – общее количество входных связей и порядковый номер подслоя, соединенного с обучаемым нейроном соответственно. Параметр $\min_{\forall v} (U_{Cl}(n+v, p))$ введен в соотношение с целью исключения в рецепторной подгруппе влияния постоянной составляющей, что необходимо для того, чтобы НС была инвариантна к изменению яркости распознаваемого изображения. $U_{Cl}(n, k)$ определяется как $\max(U_{Sl-1}(n+v, p))$, $\forall v \in Dl, \forall p \in P$, где l – порядковый номер слоя; p, P – порядковый номер плоскости и множество плоскостей из предыдущего S -слоя соответственно; Dl – двухмерная величина, характеризующая размеры рецепторных подгрупп \tilde{C} -нейрона; v – двумерный индекс связи внутри этих подгрупп.

\bar{C} -подслоем состоит из \tilde{C} -нейронов, которые обобщают один признак из предыдущего подслоя. Обобщение означает, что если в рецепторном поле \tilde{C} -нейрона обнаруживается хотя бы один активный нейрон, то \tilde{C} -нейрон тоже переходит в активное состояние, т.е. выполняется функция ИЛИ нечеткой логики по всему рецепторному полю нейрона и ее значение присваивается выходному сигналу нейрона.

Обычно рецепторное поле \tilde{C} -нейрона образуется в одном подслое предыдущего слоя либо в нескольких, когда признаки, выделяемые этими подслоями, необходимо объединить, чтобы получить более сложный признак. Например, когда в \bar{C} -подслое выделяется признак перепада яркости, то связи от этого \bar{C} -подслоя необходимо устанавливать с двумя \bar{S} -подслоями из предыдущих слоев, первый из которых выделяет признак перепада яркого на темный, а второй – с темного на яркий. Положение подгрупп рецепторных полей для \tilde{C} -нейрона определяется так же, как и для \tilde{S} -нейрона.

НС, которая применялась при экспериментах, содержала слои R , S_1 , C_1 и S_2 . Размер рецепторного слоя равен размеру образа элемента ИС. S_1 -слой предназначен для выделения общих признаков, встречающихся у всех элементов ИС, таких, как линейные границы перепадов яркостей различной ориентации. Все подслои этого слоя состоят из нейронов с одинаковыми размерами подгрупп рецепторного поля 4×4 нейрона. Обучающие образы для этих подслоев изображены на рис. 2.

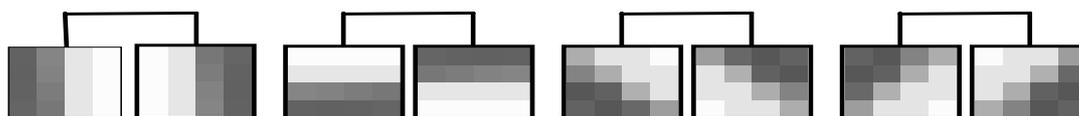


Рисунок 2 – Обучающие образы S_1 -слоя

C_1 -слой предназначен для обобщения признаков, выделяемых в S_1 -слое, а рецепторные подгруппы его нейронов организованы таким образом, чтобы объединять такие парные признаки, как вертикальные перепады яркости с темного на светлый и со светлого на темный. Эти признаки объединены на рис. 3 горизонтальной прямоугольной скобкой. В результате получаем четыре подслоя в C_1 -слое. Размер подгрупп рецепторного поля выбран такой, чтобы активность нейронов из этого слоя была инвариантна по отношению к малым сдвигам признаков, выделяемых в предыдущем слое, и составляет поле 2×2 .

S_2 -слой предназначен для выделения совокупности признаков, присущих одному конкретному элементу ИС. Поскольку S_2 -слой формирует выходное значение сети, то он состоит из одного \tilde{S} -нейрона, а размеры подгрупп рецепторного поля этого нейрона совпадают с размером \bar{C} -подслоев из предыдущего слоя. Так как весовые коэффициенты этого нейрона хранят уникальную информацию об искомом изображении, то возможно создание базы данных элементов ИС.

Поиск объекта осуществляется следующим образом.

1. Запросить у оператора образцы изображений искомых элементов или загрузить указанную архитектуру из БД.
2. Сформировать архитектуру для поиска элементов на изображении ИС.
3. Сохранить в БД информацию об архитектуре НС (размер рецепторного слоя и матрицы весовых коэффициентов выходного \tilde{S} -нейрона).
4. Осуществить поиск элементов на изображении ИС и сформировать файл, содержащий координаты мест расположения указанного элемента.

Анализ и классификация

С целью улучшения характеристик обработки информации и точности распознавания был проведен анализ структуры неокогнитрона и разработана архитектура многослойной НС, которая реализует многоуровневый процесс распознавания. В основе правила активации нейронов лежит новый метод сравнения матриц яркостей изображений, который позволяет сравнивать матрицы с нечетким позиционированием соответствующих элементов матриц. При этом функция активации определяется формулой

$$c = 1 + \frac{n \sum_{x,y} (w_{x,y} a'_{x,y}) - \sum_{x,y} w_{x,y} \sum_{x,y} a'_{x,y}}{\sqrt{\left(n \sum_{x,y} (w_{x,y} a'_{x,y}) - \left(\sum_{x,y} w_{x,y} \right)^2 \right) \left(n \sum_{x,y} (w_{x,y} a'_{x,y}) - \left(\sum_{x,y} a'_{x,y} \right)^2 \right)}}, \quad (1)$$

где n – количество точек в эталонной матрице; $w_{x,y}$ – значения точек в эталонной матрице; $a'_{x,y}$ – значения соответствующих точек на анализируемом изображении,

$$a'_{x,y} = \begin{cases} 0, & \left[\min_{rx=-R, \dots, R; ry=-R, \dots, R} (a_{x+rx, y+ry}); \max_{rx=-R, \dots, R; ry=-R, \dots, R} (a_{x+rx, y+ry}) \right] \cap \\ & \left[\min_{rx=-R, \dots, R; ry=-R, \dots, R} (w_{x+rx, y+ry}); \max_{rx=-R, \dots, R; ry=-R, \dots, R} (w_{x+rx, y+ry}) \right] \neq \emptyset; \\ a_{x,y}, & \left[\min_{rx=-R, \dots, R; ry=-R, \dots, R} (a_{x+rx, y+ry}); \max_{rx=-R, \dots, R; ry=-R, \dots, R} (a_{x+rx, y+ry}) \right] \cap \\ & \left[\min_{rx=-R, \dots, R; ry=-R, \dots, R} (w_{x+rx, y+ry}); \max_{rx=-R, \dots, R; ry=-R, \dots, R} (w_{x+rx, y+ry}) \right] = \emptyset. \end{cases}$$

Параметр R – радиус геометрических искажений, определяющий максимально допустимое смещение пикселей эталона на изображении (образе), вычисляется по формуле $R = [0,3 \times 1/F]$, где

$$F = \frac{F_h + F_v}{2}, \quad (2)$$

$$F_h = \frac{1}{X} \left(1 + \frac{1}{Y} \sum_{x=1, y=1}^{X-1, Y} \delta(g_{x,y}^h, g_{x+1,y}^h) \right), \quad F_v = \frac{1}{Y} \left(1 + \frac{1}{X} \sum_{x=1, y=1}^{X, Y-1} \delta(g_{x,y}^v, g_{x,y+1}^v) \right),$$

$g_{x,y}^h, g_{x,y}^v$ – значения вертикального и горизонтального градиентов в точке (x, y) ,

$$\delta(a, b) = \begin{cases} 1, & \text{sign}(a) \neq \text{sign}(b); \\ 0 & \text{в остальных случаях.} \end{cases}$$

В результате применения (1) получаем значения в интервале $c \in [0; 2]$, где значения $c \in [0; 1)$ говорят об обратной корреляции, значения $c = 1$ – об отсутствии корреляции, а значения $c \in (1; 2]$ – о прямой корреляции.

Метод многоуровневой классификации обеспечивает более устойчивую классификацию изображений благодаря иерархической организации признаков изображения, идентифицируемых классификатором. Уровни иерархии признаков соответствуют уровням классификатора, где каждый признак следующего уровня комбинирует пространственное расположение признаков предыдущего уровня, формируя более «крупный» признак, где на последнем уровне распознается все входное изображение целиком.

В рассматриваемой здесь постановке задачи распознавания предполагается, что существует набор изображений объектов, в котором каждый объект представлен несколькими изображениями, отличающимися друг от друга. Чтобы сформировать такое множество, разделим все изображения объектов на три множества: обучающее, тестовое для обучения и тестовое. *Обучающее множество* – это множество изображений объектов, которое формируется как результат алгоритма формирования обучающего множества. Главной характеристикой является его репрезентативность, т.е. достаточность различных представлений объекта на изображении для того, чтобы классификатор смог распознать все остальные возможные вариации представления объекта. *Тестовое множество для обучения* – это некоторая небольшая часть общего множества изображений, которая используется при формировании обучающего множества. Будем считать, что тестовое множество для обучения является репрезентативным, но в то же время избыточным. Избыточность заключается во включении в множество таких элементов, которые можно исключить из процесса обучения. *Тестовое множество* – это большая часть общего множества изображений.

Теперь для формирования обучающего множества выполняются следующие действия:

1. Выбрать в обучающее множество по одному экземпляру изображений каждого класса из тестового множества для обучения.
2. Произвести обучение.
3. Выполнить распознавание на тестовом множестве для обучения.
4. Добавить в обучающее множество экземпляры изображений каждого класса, которые не были распознаны.
5. Повторить пп. 2 – 4 до тех пор, пока не будет достигнут требуемый уровень распознавания.

После построения обучающего множества для каждого слоя решается задача кластеризации входных данных слоя, к которой сводится задача обучения слоя. Поиск лучшей архитектуры НС осуществлялся следующим методом. Для различных вариантов архитектуры она обучалась на обучающем множестве, затем тестировалась на тестовом множестве для обучения. По результатам тестов выбиралась лучшая архитектура. Чтобы сравнить качество распознавания в целом, проводилось тестирование классификатора, основанного на стандартном корреляционном методе идентификации.

Структура нейросетевой системы обработки изображений показана на рис. 3.



Рисунок 3 – Структура нейросетевой системы

Заключение

Разработанные конкурирующие НС (многослойный перцептрон, самоорганизующиеся карты Кохонена и их комбинации), а также методы их обучения обеспечивают стабильность и снижение вычислительной сложности процесса обучения при нечеткой информации об объектах топологии. В целом использование предложенных методов при разработке СТЗ позволяет в несколько раз сократить объем вычислительных операций при увеличении достоверности распознавания объектов на изображениях.

Литература

1. Гонсалес Р. Цифровая обработка изображений. – М.: Техносфера, 2005. – 1072 с.
2. Абламейко С.В. Обработка изображений: технология, методы, применение. – Минск: Ин-т техн. кибернетики НАН Беларуси, 2000. – 304 с.
3. Fukushima K. Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position // Biol. Cybern. – 1980. – Vol. 36. – P. 193-202.
4. Галушкин А.И. Теория нейронных сетей. Кн. 1: учеб. пособие для вузов. – М.: ИПРЖР, 2000. – 528 с.
5. Сигеру Омагу. Нейроуправление и его приложения. Кн. 2 Пер. с англ. Н.В. Батина / Под ред. А.И. Галушкина, В.А. Птичкина. – М.: ИПРЖР, 2000. – 272 с.
6. Головкин В.А. Нейронные сети: обучение, организация и применение. Кн. 4: учеб. пособие для вузов / Под общей ред. А.И. Галушкина. – М.: ИПРЖР, 2001. – 256 с.
7. Терехов В.А. Нейросетевые системы управления. – СПб: Изд-во С-Петербургского университета, 1999. – 265 с.
8. Розенблатт Ф. Принципы нейродинамики: Перцептрон и теория механизмов мозга: Ф. Пер. с англ. – М.: Мир, 1965. – 480 с.
9. Fukushima K. Neocognitron: A neural network model for a mechanism of visual pattern recognition // IEEE Trans. Syst., Man, Cybern., V. SMC-13. – 1983. – P. 826-834.
10. Reid M.B. Simultaneous position, scale, and rotation invariant pattern classification using third-order neural networks // International Journal of Neural Networks. – Research & Applications. – 1989. – № 1 (3). – P. 154-159.
11. Vaillant R. Original approach for the localisation of objects in images // IEE Proc on Vision, Image, and Signal Processing. – 1994. – № 141(4). – P. 245-250.
12. Lovell D.R. The performance of the Neocognitron with various S-cell and C-cell transfer functions. – Intelligent Machines Lab., Dept. of Elec. Eng., Univ. of Queensland, 1992.
13. Satoh S. Recognition of rotated patterns using neocognitron // Proc. Int. Conf. Neural Information Processing. – 1997. – № 1. – P. 112-116.
14. Wiskott L. How does our visual system achieve shift and size invariance // Problems in Systems Neuroscience. – 2003.
15. Pan Z. Staged Training of Neocognitron by Evolutionary Algorithms // Proceedings of the Congress on Evolutionary Computation. – 1999. – № 3. – P. 1965-1972.
16. Wersing H. Learning Optimized Features for Hierarchical Models of Invariant Object Recognition // Neural Comp. – 2003. – № 15 (7). – P. 1559-1588.
17. Behnke S. Meter Value Recognition using Locally Connected Hierarchical Networks // Proceedings of 11th European Symposium on Artificial Neural Networks. – 2003. – P. 535-540.
18. Scalzo, F. Statistical learning of visual feature hierarchies // IEEE Workshop on Learning in CVPR. – 2005.
19. Садыхов Р.Х. Обработка изображений и идентификация объектов в системах технического зрения // Искусственный интеллект. – 2006. – № 3. – С. 634-643.
20. Ваткин М.Е. Идентификация объектов на цветных изображениях топологического слоя интегральной схемы // Информатика. – 2005. – № 4 (8). – С. 57-67.

Doudkin A.A.

Neural Network Technology of Object Recognition on Integrated Circuits Layouts

Methods and algorithms for image processing and recognition based on neural network are considered, that are applied to computer vision systems for CAD of integrated circuits. A structure of a computer vision software system is proposed implemented neural network technology of Object Recognition on Integrated Circuits Layouts.

Статья поступила в редакцию 24.07.2008.