

О НЕЙРОСЕТЕВОМ КОНТРОЛЕ КАЧЕСТВА ПРИ ПОТОЧНОМ ПРОИЗВОДСТВЕ

И.Ф. ЯСИНСКИЙ

(Ивановская государственная текстильная академия)

Автоматизация обнаружения дефектов при поточном производстве с помощью нейросетевой технологии актуальна для многих отраслей промышленности (текстильная промышленность, производство бумаги, производство металлического листа и т.д.). Ниже излагаются некоторые проблемы, возникающие на этом пути, и предлагаются способы их решения.

Рассмотрим контроль качества движущегося одноцветного полотна ткани [1].

Эффективность распознавания образов резко возрастает, если объект неподвижен. Конечно, один из выходов состоит в применении мгновенного покадрового электронного фотографирования ткани. При этом выдержка должна быть очень короткой, чтобы изображение не получилось смазанным.




Рис. 1




Рис. 2

Однако возможен и другой подход. Он состоит в применении вращающейся батареи небольших и достаточно дешевых аналоговых видеокамер (рис.1) или зеркальной призмы (рис.2). Такие устройства позволяют держать распознаваемый объект в поле зрения камеры достаточно долго – пока он не пройдет всю подконтрольную область. На рис. 1 и 2: 1 – движущееся полотно; 2 – подконтрольная площадь; 3 –

участок полотна, находящийся в поле зрения камеры; 4 – вращающийся блок видеокамер (рис.1) или одна видеокамера (рис.2) и 5 – вращающаяся зеркальная призма.

Сам факт существования дефекта на полотне без его классификации достаточно просто обнаруживается при сканировании изображения посредством вычисления разностным способом первых и вторых производных по продольной (x) и попе-

речной (y) координатам от освещенности обозреваемого поля (рис.3).




Рис. 3

Удобно в качестве индикатора дефекта воспользоваться величиной

$$I = \alpha_1 (F - F_0)^2 + \alpha_2 \left(\left(\frac{\partial F}{\partial x} \right)^2 + \left(\frac{\partial F}{\partial y} \right)^2 \right) + \alpha_3 \left(\left(\frac{\partial^2 F}{\partial x^2} \right)^2 + \left(\frac{\partial^2 F}{\partial y^2} \right)^2 \right). \quad (1)$$

Здесь $F(x,y)$ – освещенность обследуемого поля; F_0 – средняя освещенность; $\alpha_1, \alpha_2, \alpha_3$ – весовые коэффициенты.

При разностной аппроксимации (рис.3) поля вместо $F(x,y)$ имеем F_{ij} :

$$\begin{aligned} \left(\frac{\partial F}{\partial x} \right)_{ij} &= \frac{F_{i+1j} - F_{i-1j}}{2h_x}, \\ \left(\frac{\partial F}{\partial y} \right)_{ij} &= \frac{F_{ij+1} - F_{ij-1}}{2h_y}, \\ \left(\frac{\partial^2 F}{\partial x^2} \right)_{ij} &= \frac{F_{i+1j} - 2F_{ij} + F_{i-1j}}{h_x^2}, \\ \left(\frac{\partial^2 F}{\partial y^2} \right)_{ij} &= \frac{F_{ij+1} - 2F_{ij} + F_{ij-1}}{h_y^2}. \end{aligned} \quad (2)$$

Превышение величиной I_{ij} некоторого критического значения $I_{кр}$ означает наличие дефекта в точках с координатами i, j . Величины $I_{кр}, \alpha_1, \alpha_2, \alpha_3$ и шаги дискретизации h_x, h_y подбираются.

Численные эксперименты показали, что

классификация дефектов существенно улучшается, если обнаруженный дефект переносится в центр рецепторного поля нейронной сети и при помощи масштабных множителей растяжения-сжатия проецируется на большую часть рецепторного поля. Соответствующие формулы для этих преобразований здесь не приводятся из-за их простоты.

Обучение нейронной сети можно проводить в двух режимах: внутренней и внешней демонстрации. При внутренней демонстрации большое число типичных дефектов на ткани фотографируется и размещается на винчестере компьютера. Их число увеличивается посредством масштабных изменений и сдвигов по контролируемому полю. Для получения этих производных дефектов используется генератор случайных чисел.

Сформированное таким образом множество дефектов делится на два подмножества: обучающее и контролирующее. С помощью обучающего подмножества выполняется настройка весовых коэффициентов нейронной сети [2], а при помощи контролирующего подмножества оценивается эффективность распознавания. Обучающее множество и распознающая система находятся в одном компьютере. При этом изображения дефектов на монитор не выдаются, что позволяет получить высокие скорости обучения.

При внешней демонстрации эффективность контроля оценивается так, как показано на рис.4.




Рис.4

Здесь $K1$ – компьютер, демонстрирующий на мониторе $M1$ множество возможных дефектов; BK – видеокамера; $K2$ – компьютер, содержащий настроенное нейросетевое математическое обеспечение. $K2$

получает от видеокамеры предъявленные образы и распознает их. Результаты работы выдаются на монитор М2.

Компьютер К1 содержит в памяти все множество сформированных дефектов и показывает их на экране монитора М1. Быстрота показа может меняться в широких пределах. Компьютер К2 подключен к видеокамере, которая направлена на экран компьютера К1, и содержит уже настроенное нейросетевое математическое обеспечение, он распознает образы, которые предъявляет первый компьютер. Такой эксперимент позволяет исследовать эффективность системы в целом, включая пропускную способность видеоканала.

С помощью описанного устройства удобно выполнить отладку и исследование нейросетевого контролирующего устройства в целом до его постановки на мерильно-браковочные машины в цехе. В частности, оценить эффективность и допустимое

повышение производительности браковочного оборудования.

ВЫВОДЫ

Предложены устройства и способы, повышающие эффективность нейросетевого контроля качества при поточном производстве.

ЛИТЕРАТУРА

1. *Харахнин К.А., Ясинский И.Ф.* // Изв.вузов. Технология текстильной промышленности. – 2003, № 4. С.98...101

2. *Ясинский И.Ф., Ясинский Ф.Н., Харахнин К.А., Сидоров С.Г.* // Вестник ИГТА. –2003, № 3. С.145...147.

Рекомендована кафедрой прикладной математики и информационных технологий. Поступила 10.02.05.
