


III JORNADAS de VISIÓN ARTIFICIAL



Málaga
13 de Octubre de 1994

Organizan:

Departamento de Ingeniería Eléctrica, Electrónica y de Control
ETSII - UNED

Departamento de Ingeniería de Sistemas y Automática
ETSII - UPM

Departamento de Ingeniería de Sistemas y Automática
ETSII - Universidad de Málaga

Patrocina:

CICYT (Plan Nacional de Tecnologías Avanzadas de la Producción)

Sistema híbrido de clasificación de defectos en planchas de aluminio

Carlos Platero †, Carlos Fernández† , Pascual Campoy, y Rafael Aracil
Dpto. de Sistemas y Electrónica (DISAM)
Universidad Politécnica de Madrid
C/José Gutiérrez Abascal,2
28006 MADRID
cplatero@disam.upm.es

Resumen

El artículo describe las técnicas de Inteligencia Artificial aplicadas para la interpretación de imágenes de superficies de aluminio con defectos. La totalidad del proceso incluye la detección en on-line del defecto, la segmentación, la extracción de características y la clasificación. Estos tópicos son discutidos en profundidad.

El pre-procesado de los datos, así como la segmentación y la extracción de defectos son comentados. En este punto se discute la algorítmia empleada y los descriptores usados. El filtro sintáctico modela la información generando el vector de entrada a la etapa de clasificación.

En la clasificación de defectos se han utilizado sistemas basados en reglas, modelos borrosos y redes neuronales. Se mantiene una filosofía de diferentes subsistemas de clasificación para la resolución de un problema de reconocimiento de patrones (sistemas híbridos). En primer lugar, haciendo uso de métodos sintácticos, se obtiene una representación virtual del defecto. Posteriormente, un grupo de técnicas se emplea para el reconocimiento, sistemas basados en reglas, clasificadores borrosos y redes neuronales. La clasificación mediante reglas hace asociar a cada defecto un tipo de gramática. La base de conocimiento estará formado por la información derivada del filtro sintáctico y las reglas inferidas. Los clasificadores borrosos utilizarán reglas de producción con antecedentes borrosos y sus consecuentes son grados de pertenencia a un tipo de defecto. Distintas arquitecturas de redes neuronales han sido implementadas con diferentes resultados, las conclusiones son comentadas. En un estadio superior de clasificación, un supervisor se nutre de la información aportada por los sistemas heterogéneos más la historia del proceso para determinar la conclusión final.

I. Introducción

En el diseño de un sistema de reconocimiento, desde un punto de vista general, puede estar englobado en la construcción de cuatro bloques [Bezdek y Pal, 1992].

1. Descripción del proceso (variables que intervienen en él)
2. Análisis de características (exploración y transformación de datos)
3. Determinación de agrupamientos (procedimiento de Clustering)
4. Diseño del clasificador

Una de las características de los sistemas de reconocimiento de patrones es la imprecisión que se presenta:

1. Por la propia topología del defecto, cuyas apariencias no son exactamente las mismas.
2. Y la propia determinación de la estructura de los datos (clustering) o del diseño del Clasificador.

Los vectores de característica de entrada sufren de los errores propios de una adquisición basada en cámaras, cambios de iluminación, movimientos bruscos en el tren de laminado del aluminio, tonalidades de defectos que satura el algoritmo de Visión Artificial. Estas razones deberán ser tenidas en cuenta en el diseño de los dos primeros bloques.

† Profesor del Dpto. de Física Aplicada e Ingeniería de Sistema, EUITI, UPM, Madrid

En cuanto a la agrupación de objetos y diseño del clasificador, dada la vaguedad de los datos que representa un defecto, se puede afirmar la necesidad de hacer uso de diferentes técnicas para su resolución, técnicas de Inteligencia Artificial, modelos borrosos, sistemas basados en reglas y redes neuronales.

La descripción del proceso tiene como misión recoger la información que represente a éste, que en este caso supone, la adquisición de imágenes y el tipo de iluminación necesaria. Su discusión se analizará en el apartado 2.1.

El análisis de característica trata de la colección de métodos y estrategias utilizadas para explorar y mejorar los datos de partida, disminuyendo sensiblemente la dimensión del vector de entrada. Para tal fin, se hace uso de algoritmos de Visión Artificial implicando la utilización de técnicas de procesado, segmentación y extracción (apartado 2.2 y 2.3)

Dado el conjunto finito de objetos obtenidos de las etapas anteriores, el problema de definir agrupamientos, consiste en asignar etiquetas de pertenencia que identifiquen subgrupos en el mismo, según un criterio de similitud. El objetivo de este bloque es, en suma, realizar una partición en un número de subconjuntos naturales y homogéneos, donde los elementos de cada subconjunto deben ser tan similares entre sí como sea posible y diferentes (según la misma relación) de los otros subconjuntos. Realizar esta partición de forma adecuada solucionará ciertas cuestiones referentes a la descripción del proceso, lo que ayudará al correcto diseño del clasificador[Ruiz, Barro, Presedo, 1992].

Utilizando métodos sintácticos se consigue agrupaciones de objetos alrededor de una primitiva, que constituirá la representación virtual del defecto. Esta información formará la parte esencial del vector de entrada a los diferentes clasificadores.

Por último, el diseño del clasificador a partir de unos prototipos para determinar las fronteras de cada defecto presenta inconvenientes por el carácter impreciso de la propia estructura de las elases. Las aproximaciones convencionales tienen como objetivo estimar de forma exacta el área de cada clase, sin solape con ninguna otra (MLPs con algoritmo de backpropagation). Sin embargo sucede que existe determinada representación de defectos en posiciones fronteras o puntos singulares, lo que sugiere el uso de sistemas basados en reglas con variables borrosas y arquitecturas neuronales como LVQs y ARTs. El uso de modelos borrosos sugiere emplear grados de pertenencia de manera que paliase la dificultad anteriormente expuesta. (apartado 4)

II. Sistema de inspección visual

El sistemas de Inspección Visual desarrollado para la detección de defectos en planchas de aluminio está formado por: Sistemas de iluminación, dispositivos de adquisiciones de imágenes, módulo de detección de defectos, medidas de acabado superficial, módulo de extracción de características y módulo de clasificación.

El método de trabajo corresponde con el esquema clásico de resolución de problemas haciendo intervenir técnicas de Visión Artificial, tal como muestra la figura 1.



Figura 1

2.1 Sistema de iluminación y dispositivos de adquisición de imagen

Los defectos en superficies metálicas se caracterizan por alteraciones en la microestructura superficial. Puesto que los defectos que aparecen en las superficies metálicas suponen una alteración material de las mismas, la observación de la componente especular de la luz reflejada da como resultado la detección de defectos. Debido al alto coeficiente de reflexión de la superficie del aluminio se convierte una necesidad diseñar un sistema de iluminación capaz de iluminar uniformemente la lámina, evitando cualquier tipo de reflejo [Bechmann 1963].

Las pruebas acometidas en el laboratorio sobre iluminación difusa y especular, llego a mostrar que el Sistema de Iluminación Especular es el mas apropiado (figura nº2).

Se han adoptado cámaras CCD matriciales como las más apropiadas para la aplicación, principalmente por dos razones: la velocidad máxima de la banda no supera los 2 m/sg, lo que permite tiempos de adquisición de 10 msg y , la más importante, la necesidad de procesamiento en entorno de vecindad (apartado 2.2), puesto que la superficie presenta una notable textura, no permitiendo procedimientos basados en umbrales (principal característica del procesado de cámaras lineales).

Las especificaciones iniciales para el sistema de inspección son:

- 1 mm² el tamaño del menor defecto.
- Ancho de la plancha 1500 mm.
- Velocidad del proceso 1m/mim, (17 mm/sg).

Utilizando una resolución media (3 pixel/mm) con cámaras CCD (752 x 528 pixels), ocho cámaras (cuatro cámaras por cada una de las caras de la plancha) serán necesarias para cubrir el ancho de 1,5 m. En este caso el tiempo de análisis para cada una de las imágenes está alrededor de 2.1 segundos, la superficie de plancha cubierta por cada cámara es de 376 mm de ancho por 291 mm en la dirección del laminado. En este tiempo la presencia / ausencia del defecto deberá ser decidido, objetivo que es ampliamente cumplido.




Figura 2

2.2 Módulo de procesado de imágenes

Una vez obtenida la imagen del aluminio se procesa para encontrar defectos. Para la localización de defectos se realiza un análisis local, pues debido a la textura y tipo de iluminación

utilizada no es posible un enfoque global; puntos claros aparecen entremezclados con otros más oscuros; algunos defectos no producen una variación significativa en los valores absolutos de nivel de gris, sino que producen una alteración en la distribución espacial de los mismos.

Previa al procesado de la imagen, se adquiere la imagen con la máxima apertura del diafragma permitido, sin evitar saturaciones, manteniendo el máximo rango de medida con la mejor cuantificación de la señal. Posteriormente, la imagen es desplazada menos n niveles de grises para evitar desbordamientos en las etapas de procesado.

Algoritmos basados en similitud así como análisis textural han sido desarrollados para la detección de defectos. Según las conclusiones de [Lee, Chung y Park, 1990] se admite que los métodos de parámetros estadísticos simples son los óptimos para la aplicación de visión artificial en tiempo real. Los algoritmos de detección se basan en considerar que la distribución de niveles de grises en un franja con igualdad en la iluminación sobre una probeta de aluminio, corresponde a una función de densidad gaussiana; cuya media corresponde con la cantidad de iluminación y la naturaleza de la materia, manteniéndose aproximadamente constante la varianza.

Se considerará un pixel no defectuoso, aquel que cumpla:

$$m(x, y) - X_1 \leq p(x, y) \leq m(x, y) + X_2$$

siendo $m(x, y)$ la media del patrón para el pixel y X_1 y X_2 las cuantías de niveles de grises alrededor de la media sin considerarlo defectuoso. Las etapas de procesamiento son mínimas, media en el entorno de vecindad y comparación local con patrones, lo que permitirá definir defectos con apariencia "clara" u "oscura". Posteriormente, se pasa a la detección de presencia/ausencia de defectos con un simple histograma de las imágenes resultantes [Fernández, Platero, Campoy y Aracil, 1993].

La ausencia de defectos propiciará la renovación de los patrones, con el fin de eliminar defectos producidos por el desgaste en las lámparas, presencia de polvo, envejecimiento de los dispositivos ópticos de las cámaras o variación en los niveles de luz natural de la planta.

La presencia de defectos originará una etapa de etiquetado de los objetos, en objetos claros y oscuros. En el caso de que el número de objetos fuera excesivo (caso de los sticking) se pasará a aumentar los umbrales locales (X_1 , X_2) llevando consigo la formación de nuevos patrones. La experiencia ha demostrado que la identificación de un defecto no requiere de un número excesivo de objetos, pues las presentaciones de éstos mantienen características espaciales bien diferenciadas. Por tanto, la umbralización local es de carácter dinámico y su valor dependerá de la calidad de fabricación del aluminio y del defecto a detectar.

Con posterioridad se pasará a una etapa de extracción de características. La figura 3 muestra la detección de un defecto real en la banda. En la izquierda aparece el defecto de mala cristalización; en el centro aparece el defecto segmentado y en la derecha se puede apreciar los rectángulos que engloban a los objetos.




Figura 3

2.3 Extracción de características y filtro sintáctico

Uno de los principales problemas en el reconocimiento de patrones es la selección de las mejores características posibles para un problema dado. El método empleado consiste en obtener mediante las técnicas comentadas en el apartado anterior (2.2) los objetos que representan los defectos presentes en la imagen. El uso de un filtro sintáctico realizó la selección de los descriptores de los objetos y por ende definió la etapa de extracción de características.

En un primer ensayo se extrajo el mayor número posible de atributos de los objetos, características de la forma de los límites y de las regiones con técnicas de transformación escalar, atendiendo a la clasificación de Pavlidis [Vernon, 1991]. Las diferentes fases de decantación de las primitivas provocaron la selección de los descriptores de los objetos.

El conocimiento de direcciones privilegiadas de los defectos en bandas transversales u horizontales ó en manchas, hizo sugerir transformar parte de la información cuantitativa en algo más cualitativo. El filtro sintáctico permitía tener una información más abstracta, más cualitativa y el volumen de información era bastante menor. Con objeto de reducir el problema a un lenguaje de concatenación, se hace uso del PDL (Picture description language). Se definen en términos de primitivas, y asociada con ellas se pasan atributos de mayor nivel de abstracción que en la etapa de objetos.

Estas primitivas serán las fuentes de información para el modulo de clasificación ya sea basado en sistemas con reglas ó con redes neuronales. Y aunque esto se verá más adelante, es de recordar que las primitivas pueden ser unidas entre ellas mediante reglas de producción asociado a una determinada gramática. Las gramáticas generadas por el PDL son de libre contexto [Fu 1982]

2.3.1 Método de obtención de las primitivas

Una vez detectado el defecto, segmentado y etiquetado. La tarjeta de visión pasará los descriptores de los objetos que servirán de vector de entrada al filtro sintáctico. Posteriormente se hace una ordenación por áreas de los objetos en cada ROI (región de imagen de interés), se caracteriza cada objeto por su forma (puntos, manchas, cuerpos longitudinales y cuerpos transversales) y su compacidad. Seguidamente se asocian objetos a un elemento terminal a partir de los objetos mas significativos (semillas), utilizando principios de continuidad y proximidad, a partir de los centro de gravedad y buscando orientaciones privilegiadas (figura nº4). Ultimando la operación con el etiquetado y paso de características de medio nivel de los elementos terminales.

Agrupación de objetos en elementos terminales




Figura 4

3. Módulo de clasificación

El problema de reconocimiento de defectos no es una tarea fácil, la solución viene dada por la conjunción de diferentes técnicas de Inteligencia Artificial, que en palabras de Laveen Kanal presenta un 'sistema híbrido' [Kanal y Raghavan, 1992]. Es conocida la necesidad de intervenir distintos caminos para el reconocimiento, en este caso se ha hecho uso de redes neuronales, sistemas basados en reglas y clasificadores borrosos.

La información procedente del filtro sintáctico es el vector de entrada común a todos los subsistemas que constituye el módulo de clasificación. Cada subsistema aporta una clasificación y estos tienen características complementarias. Los vectores de salida de estos formarán la entrada del otro estadio de clasificación. En un sistema experto se decide con los datos provenientes de la etapa anterior el tipo de defecto.

Buscar subsistemas de clasificación con características complementarias hizo elegir las técnicas a emplear. La información de primitivas y PDL aconsejaba el uso de gramáticas de libre contexto para cada tipo de defecto, por tanto se diseñó un bloque basado en reglas de producción. Artículos con características parecidas a la solución de este problema abogaban por el uso de redes neuronales [Sikka, 1992]. Por último, los clasificadores borrosos suponen una mejora en sistemas basados en reglas [Ruiz, Barro, Presedo, 1992]. De esta etapa de análisis salió como resultado el primer nivel de clasificación, formado por:

1. Sistemas basados en reglas. Uso de gramáticas de libre contexto para cada tipo de defecto, supervisores y clasificadores borrosos.
2. MLPs con algoritmos de aprendizaje de backpropagation por su capacidad de generalización.
3. Red LVQ por tener un clasificador basado en el vecino más cercano.
4. Red ART para la determinación de nuevos tipos de defectos.

Por cada defecto se tendrá un árbol de información, en el que cada nodo de este árbol, estarán presentes los elementos terminales y la información de medio nivel, de cada uno de las regiones de imagen de interés implicados en el defecto (figura nº5).




Figura 5

El estadio superior está formado por un supervisor neuronal que elaborara la conclusión definitiva. Los siguientes párrafos se dedican a comentar la constitución de cada uno de ellos.

3.1 Subsistemas basadas en reglas

La caracterización de un clasificador pasa, en primer lugar, por la definición de un conjunto de vectores de etiquetas en \mathfrak{R}^c , siendo c el número de clases. Si se tratara de un clasificador "hard", los vectores de etiquetas para las c clases se definen:

$$N_c = \{ y \in \mathfrak{R}^c \mid \sum y_k = 1 \quad ; y_k \in \{0, 1\} \forall j \}$$

Si el clasificador es borroso, los vectores de etiquetas para c clases se definirán:

$$N_{fc} = \{ y \in \mathfrak{R}^c \mid \sum y_k = 1 \quad ; y_k \in [0, 1] \forall j \}$$

Reflejando dos maneras distintas de diseñar clasificadores basados en reglas, los primeros basados en particiones convencionales y los otros configurando un clasificador borroso

3.1.1 Clasificador convencional mediante reglas

Está formado por dos grupos de software, el primero realiza un análisis de las distintas primitivas que compone el defecto, es decir, se detecta que tipo de primitivas están presentes en el defecto (a lo largo de todas las regiones de interés que ocupe éste) y cuales son las masa totales de cada una de las primitivas. Con esta información se ha inferido un conjunto de reglas de tipo estadístico.

El segundo grupo de reglas se basan en métodos sintácticos y son más complejo que el anterior. Mantiene como objetivo la justificación de las primitivas por su situación espacial y que el conjunto de éstas deberá corresponder a la topología de un defecto. Se ha visto hasta ahora que las gramáticas son generadores de modelos. Los conceptos básicos se pueden ilustrar mediante el desarrollo de un conjunto de reglas que al aplicar sobre la sentencia devolverá si es válido ó no para esa gramática. Cada tipo de lenguaje, una para cada defecto, genera un particular tipo de conjunto de reglas [Fu, 1988]. En la mayoría de los casos las gramáticas no son conocidas a priori y ello debe ser inferido desde un conjunto de muestras. La idea básica de inferencia gramatical es encontrar el conjunto de reglas que son obtenidas desde un grupo de muestra del mismo tipo de defecto. Esto se hace para cada muestra, dando una gramática no recursiva. Las producciones redundantes son eliminadas y la gramática es hecha recursiva en orden a generar un número infinito de palabras [Banks, 1991]. Con independencia del tipo de reglas todas tienen una misma estructura que podrían definirse como:

1. Macros
2. Condiciones impuestas
3. Resultados

Los macros son los valores que se han ajustado para la limitación de las condiciones de las reglas. Estos han sido inferidos y son valores fácil de cambiar. Aparecen en el inicio de las reglas. El uso de estadísticas y de resultados ha ejercido como elemento realimentador, los macros y las

condiciones han sido variadas en búsqueda de una reglas más eficientes. La justificación de un defecto provoca la retirada de las primitivas del árbol de datos y su actuación se mantiene hasta la completa interpretación del árbol. Una vez realizado este análisis, se habrá generado una lista parcial de resultados y un supervisor de reglas estructurales devolverá el tipo de defecto.

La respuesta de éstos dos grupos de reglas son vectores de entrada al supervisor neuronal que junto a los resultados de las redes ofrecerá una salida que indica el tipo de topología de defecto y el nivel de confianza.

3.1.2 Clasificador borroso

El primer paso que hay que dar consiste en asignar los equivalentes borrosos a los valores deterministas de las entradas del sistema. Para cada variable de entrada hemos de tener definido el universo de discurso y las etiquetas lingüísticas que se van a emplear así como la función de pertenencia asociada a cada una de ellas. Las funciones de pertenencia polinómicas son funciones sencillas de calcular y tienen una forma similar a la de las funciones de densidad normales, siendo más rápidas de calcular y estas son las elegidas en la fase de borrosificación.

Variables lingüísticas en la clasificación de defectos y borrosificación

Las variables borrosas son formadas bajo concepciones descriptivas de la topología del defecto y obtenidas, en parte, de la experiencia del clasificador anteriormente expuesto. Por ejemplo una falta de material es presentada por primitivas oscuras y claras próximas entre sí, junto con masas similares. Ésta se presenta como una regla de producción:

IF ((objetos están próximos entre sí) && (masa similares)) THEN lack probable

Matriz de cuestiones. Planteamiento de reglas

Tras haber traducido los valores deterministas de las variables de entrada a valores borrosos, se pasa a aplicar aquellas reglas que puedan ser disparadas. Cada vector de entrada a nuestro sistema debe asignarse a un conjunto de m clases, habrá de descomponerse en m problemas paralelos o subclasificadores, que se aplican a cada vector de entrada x . En el caso tratado, de clasificación de defectos, son cinco las clases:

- bandas longitudinales
- bandas transversales (oscuras y claras)
- pegados (sticking)
- faltas (lacks)
- cristalización anormal

Una herramienta de ayuda para la construcción del sistema de reglas es la denominada Matriz de Cuestiones que, caso de estar completamente especificada, englobaría todas las posibilidades de combinación de cláusulas.

Sin embargo en el problema tratado, así como en la mayoría de los sistemas reales, la enumeración exhaustiva de todas las posibilidades de combinación de cláusulas es generalmente impracticable, además de presentarse un gran número de combinaciones no relevantes ó imposibles de presentarse. Por ello suele construirse una matriz parcial con sólo aquellas combinaciones de cláusulas que sean relevantes. La construcción de los diferentes subclasificadores se lleva a cabo utilizando las reglas asociadas a cada casilla con respuesta afirmativa de pertenencia ó de exclusión.

Mediante estas matrices, la evolución de un vector de datos de entrada de componente borrosa, X , en el clasificador i , se efectuará utilizando la composición asociada al $\langle \langle \text{modus ponens} \rangle \rangle$ generalizado, que opera cada una de las j matrices de implicación contenidas en el subclasificador (R_{ij}) con la entrada citada:

$$MC_i = U_j (X \circ R_{ij})$$

siendo MC_i la distribución de posibilidad de salida del subclasificador i , $\langle \langle o \rangle \rangle$ el símbolo de composiciones entre matrices, y U el símbolo de la unión (máximo) del resultado de las diferentes composiciones.

El conjunto de subclasificadores de nuestra aplicación adopta una estructura de sistemas de reglas de producción borrosa, en donde los consecuentes no son estrictamente conjuntos borrosos sino índices porcentuales de confirmación o exclusión de pertenencia del vector de entrada a un tipo de defecto. Así la forma que componen el sistema queda

IF antecedente borroso THEN (μ^c, μ^e)

siendo μ^c, μ^e los índices de confirmación y exclusión a un tipo de defecto. Con índices calculados en la evaluación de cada regla, la totalidad se efectúa combinando confirmaciones y exclusiones parciales para el conjunto completo de reglas; de esta manera se calcula el grado de pertenencia y exclusión del vector de entrada a cada tipo de defecto [Ruiz, Bravo, Presedo, 1992]

3.2 Métodos basados en redes neuronales

La clasificación de patrones mediante redes neuronales ha sido objeto de varios artículos. Algunos de ellos basan sus resultados en la obtención previa de *primitivas*, de forma similar a lo aquí tratado. Cabe mencionar el artículo de Sikka del Laboratorio de Inteligencia Artificial de Intel Corporation. Dicho autor trata de clasificar defectos lineales en obleas de silicio. Clasifican cuatro tipos de defectos mediante ocho tipos de primitivas. Tanto la descomposición del defecto en primitivas, como su posterior clasificación lo efectúan mediante redes neuronales.

Partiendo de los datos descritos en puntos anteriores (salida del filtro sintáctico), se obtendrán las entradas. Éstas estarán compuestas por unos datos de carácter general del defecto a clasificar; y por la estructura interna del mismo dada por los pesos de las primitivas que lo componen:

-Datos generales: Se especificará el ancho y largo de la totalidad del defecto; la coordenada 'y' de su centro de gravedad, no poniendo la coordenada 'x' por no ser importante; También se añade los momentos de inercia del defecto total respecto de rectas horizontal y vertical que pasan por el centro de masas (realmente se pone 10 veces el valor del momento en decibelios para tratar con números más manejables). Estos cinco datos se calculan por separado para la parte del defecto que es oscuro y para la que es claro, teniendo así los primeros 10 datos de entrada a la red.

-Datos de estructura interna: Estos datos darán la información de cómo se estructura el defecto en sus diferentes primitivas. Se da por tanto la suma de las masas de cada una de las ocho diferentes clases de primitivas que componen el defecto.

3.2.1. Arquitecturas probadas en la clasificación de defectos

Una multitud de arquitecturas se han probado (MADELINE, MLPs + Backpropagation, SOM, LVQ y ARTs), los resultados han hecho avalar como redes válidas para este problema:

1. MLP
2. LVQ
3. ART

MLP + backpropagation se ha utilizado por sus buenos resultados de generalización y por haber demostrado su eficacia en problemas similares, como en la detección de errores en obleas de silicio [Sikka, 1992].

Se ha contado con un conjunto de muestras que contenían los defectos de las cinco clases, y no todos los defectos con el mismo número de muestras. Se repartieron aleatoriamente en dos grupos, una de aprendizaje y otra de testeo ó validación. Se empezó con técnicas de cultivo [Kung, 1993] partiendo de un número de neuronas en la capa oculta y creciendo desde 2 hasta 30 neuronas. Estas redes fueron entrenadas con números de ciclos de renovación de los pesos (epochs) de 2000, 3000, 4000, 6000, 8000 y 10000, con un momento $\alpha=0.4$ y un tamaño de época de 16. El objetivo es crear una red que aprenda lo suficiente como para generalizar bien con el menor número de neuronas. Las conclusiones obtenidas son un mínimo de 6 neuronas en la capa oculta y un entrenamiento entre 4000 y 6000 epochs, estos resultados puede ser observados en la figura n°6.

Si se aplican mapas de Kohonen para el reconocimiento de patrones, la precisión en la clasificación se puede multiplicar si las células son ajustadas utilizando principios de aprendizaje supervisado (LVQ) [Kohonen, 1990]. El vector de entrada y de salida mantienen las mismas características que el empleado para la red MLP. El número total de codevectores probados ha estado comprendido entre 20 y 30, aunque los mejores resultados se obtuvieron con 25 y 26 codevectores (ver tabla I). Es muy importante no entrenar "en exceso" a la red, ya que los codevectores llegan a sintonizar tan específicamente con los datos de entrenamiento, que la habilidad del algoritmo para generalizar se ve disminuida; para el caso tratado el número de iteraciones estuvo alrededor de 1000 (la diferencia con la MLP es evidente).

El entrenamiento de los codebook se ha realizado mediante el algoritmo de OLVQ1. Y para un ajuste fino del clasificador se aplicaron los algoritmos LVQ1, LVQ2.1 y LVQ3 [Kohonen, Kangas, Laaksonen, 1992], aunque experimentalmente y tras realizar fine-tuning de los clasificadores obtenidos, no se noto mejores ventajas.

Como alternativa a las MLP y LVQ se escoge una topología de red borrosa ART. Esta elección es consecuencia de las propiedades de dicha red, que nos asegura poder clasificar nuevas categorías de defectos. Además permite trabajar con un vector de entrada analógico (en oposición al vector de las entrada de ART, de carácter digital), filtrándolo con reglas del tipo de la lógica borrosa.




Figura 6

La topología de la red de este estilo es la siguiente, existen dos capas de neuronas, la llamada de F1, que representa el vector de características; y la llamada F2, identificando las clases a clasificar. También posee dos redes de conexiones entre las dos capas, las que van en sentido F1-F2 y las que van en sentido F2-F1. De lo que se trata es que vayan pasándose la información y cambiando los pesos de una capa a otra, de forma resonante hasta que la salida sea estable. El aprendizaje es competitivo.

Esta simplificación se complementa con una serie de ganancias inhibitoras y realimentaciones que aseguren un correcto aprendizaje y una buena base para clasificar nuevas categorías.

3.3 Resultados de los clasificadores

Los resultados preliminares de los diferentes clasificadores pueden ser contemplados en la tabla I

Clasificador Defectos	Reglas Estadísticas	Reglas Estructurales	Supervisor	Clasificador Borroso	Red MLP	Red LVQ	Red ART
AB.CR	100	81.81	95.01	64.67	100	81.82	59.03
LACKS	93.75	87.50	92.50	78.95	84.67	86.96	93.20
STICK	57.14	57.14	70.98	73.12	100	90.91	83.54
LONG	66.66	77.77	75.38	86.20	85.71	95.45	73.12
TRANS	72.72	81.81	89.90	88.89	92.30	88.89	91.10

4. Configuración del sistema híbrido

Habida cuenta de que el éxito del control sobre la planta depende de la detección del tipo de defecto, se hace imprescindible la veracidad de los datos ofrecido por el sistema de inspección visual. Este motivo obliga al uso de técnicas heterogéneas que aseguren en un 100 % de la clasificación y visto los resultados aportados de las distintas técnicas, que no garantiza ninguno su clasificación al 100 %, se hace obligado el uso de un sistema híbrido (figura nº7)

De otro lado, los clasificadores anteriores solo tiene como objetivo identificar la topología del defecto con la información del conjunto de imágenes que lo forman. Ahora bien, el tipo de defecto puede venir originado de muestras pasadas, es decir, es necesario mantener presente la historia de los defectos de la bobina. Considerar estos supuestos, supondría diseño de redes recurrentes que tuviese en cuenta los estados anteriores de defectos y sistemas basado en reglas que considerase también la historia. El objetivo es dividir en dos fases, una que identificase el tipo de topología del defecto y otra que con la historia pasada decidiese de forma definitiva el defecto.

Por ejemplo, un defecto de tipo sticking suele ir acompañados durante unos cuantos metros de banda transversal oscura, éstos últimos no habrá de clasificarlos como bandas oscuras sino como defectos tipo sticking. La configuración que aquí se presenta, utiliza las redes neuronales, sistema basados en reglas y clasificadores borrosos para tener el 100 % de seguridad de la topología del

defecto. En el segundo nivel se encuentra un supervisor neuronal que inferirá con los datos de la etapa anterior y con la historia de defectos, cual es el tipo de defectos.




Figura 7

Se hace uso de los métodos sintácticos para la representación del defecto. El vector de salida del filtro sintáctico es el vector común de entrada a todos los módulos de clasificación. La clasificación esta formado por dos estadios; el primero reconoce la topología del defecto haciendo uso de redes neuronales, sistemas basados en reglas y clasificadores borrosos. El segundo estadio de clasificación corresponde a un sistema experto, que se nutre de la información del estadio inferior mas la historia del proceso de la planta. Los resultados son preliminares y se esta trabajando en ampliar el número de clases y en nuevas técnicas de clasificación.

El algoritmo de Visión Artificial se sustenta en la tarjeta IMAGE 1280 de Matrox y el interfase hombre-máquina se soporta sobre una aplicación bajo Windows 3.1. Las redes neuronales están embebidas en el software y han sido desarrollada bajo la herramienta NEURAL WORKS. El clasificador borroso ha sido desarrollado sobre GURU y actualmente no está embebido en la aplicación.

Aunque los mejores resultados se ha dado con cinco tipos de defectos, también se ha desarrollado clasificadores a ocho defectos.

El uso de librerías dinámicas para contener el código de los clasificadores junto con la herramienta de supervisión de defectos en on-line, permitirá una mejora y afinado de los clasificadores más una fácil actualización.

El trabajo futuro consistirá en el ajuste fino de los clasificadores a partir de nuevas muestras y la optimización del vector de entrada a las redes con técnicas de clustering.

5. Conclusiones

Se ha presentado un sistema de reconocimiento de defectos en planchas de aluminio basada en técnicas de Inteligencia Artificial. Algoritmos de Visión Artificial han sido utilizados en la descripción del proceso y en el análisis de las características; la presencia/ausencia de defectos en la plancha de aluminio es detectado en on-line. La ausencia provocará la renovación de los patrones y la presencia llevará consigo módulos de agrupamiento de objetos y clasificación.

6.Referencias bibliográficas

- [1] Banks, S., Syntactic Methods. Signal processing, image processing and pattern recognition (cap.20). Prentice Hall,1990.
- [2] Bezdek,J.C.,Pal,S.K., Fuzzy Models for Pattern recognition. Methods that search for structures in Data,IEEE,Inc.New York,1992.
- [3] Fernández,C.,Platero,C.,Campoy,P., Aracil,R., Vision System for On-line Inspection in Aluminum Casting Process. Proc. of IEE IECON'93,vol3,pp 1854-1859.
- [4] Fu, K. S., Robotics: Control, Sensing, Vision and Intelligence. McGrawHill, 1988
- [5] Fu, K.S., Syntactic pattern recognition with applications, Prentice Hall,1982.
- [6] Kanal, L, Raghavan, R., Hybrid systems-a key to intrlligent pattern recognition. Proceedings of the International Joint Conference on Neural Networks, pp IV 177-182, Baltimore, june 1992, IEEE.(pp IV-177,IV-182)
- [7] Kohonen, T., The Self Organization Map. Proceedings of the IEEE, vol. 78, N°9, sept.1990, pp 1464-1480
- [8] Kohonen,T. Kangas,J., Laaksonen, J. LVQ_PAK: A Program Package for the Correct Application of Learning Vector Quantization Algorithms. Proceedings of the International Joint Conference on Neural Networks, pp I 725-730, Baltimore, june 1992, IEEE.
- [9] Kung,S.K.,Digital neural networks (pp 179,185). Prentice Hall, 1993
- [10] Lee,S.U., Chung, S.Y., Park,R.H., A Comparative Performance Study of Several Global Thresholding Techniques for Segmentation, Computer Vision, Graphics, and Image Processing 52, 177-190, 1990
- [11] Ruíz,R.,Barro,S.,Presedo,J, Clasificación borrosa basada en conocimiento. Estudios de lógica borrosa y sus aplicaciones (cap.6). Universidad de Santiago de Compostela,1992
- [12] Sikka,D.,Two dimensional curve shape primitives for detecting line defects in silicon wafers Proceedings of the International Joint Conference on Neural Networks, pp III 591-596, Baltimore, june 1992, IEEE.
- [13] Vernon, D., An overview of techniques for shape description. Machine Vision (cap.7), Prentice Hall, 1991.