

Identificación de Componentes de Color con Visión Artificial y Redes Neuronales

Identification of Color Components with Artificial Vision and Neural Networks

Medina-Muñoz Luis Arturo^{1*}, Mayorquín-Robles Jesús Antonio¹, Rodríguez-Senday Jose Jesus¹, Morales-Solís Felipe¹.

1 Instituto Tecnológico de Nogales. Av Tecnológico 911, Nogales, Sonora, México, 84065.

Autor de correspondencia: Medina Muñoz Luis Arturo. Mmarturo756@gmail.com

Resumen

El presente trabajo detecta partes de plástico de 2 colores distintos, rojo y azul, mediante el uso de fotografías de las piezas, las cuales son analizadas mediante una interface escrita en el lenguaje de programación de Visual C#. Se utiliza una cámara WEB de uso común como el elemento de visión que provee la información que necesita la interface, la cual tiene una implementación de una red neuronal entrenada con el algoritmo de backpropagation. Para lograr este reconocimiento se sigue el proceso tradicional de tomar una serie de muestras como conjunto de entrenamiento y se valida el proyecto mediante la implementación del mismo en una línea de producción en una industria de manufactura local. Los resultados obtenidos mostrarán que tan eficiente es el sistema utilizando las técnicas de visión artificial para procesar la información y el uso de determinada estructura de red neuronal como elemento de reconocimiento.

Palabras clave: Redes neuronales, proceso, sistema, visión.

Abstract

The present work detects plastic parts of 2 different colors, red and blue, through the use of photographs of the pieces, which are analyzed through an interface written in the Visual C# programming language. A commonly used WEB camera is used as the vision element that provides the information needed by the interface, which has an implementation of a neural network trained with the backpropagation algorithm. To achieve this recognition, the traditional process of taking a series of samples as a training set is followed and the project is validated by implementing it on a production line in a local manufacturing industry. The results obtained will show how efficient the system is using artificial vision techniques to process information and the use of a certain neural network structure as a recognition element.

Key words: Neural Networks, process, system, vision.

DOI : 10.46588/invurnus.v18i1.79

Recibido 26/10/2022

Aceptado 26/11/2022

Publicado 14/04/2023

Introducción

Se puede definir la “Visión Artificial” como un campo de la Inteligencia Artificial que, mediante la utilización de las técnicas adecuadas, permite la obtención, procesamiento y análisis de cualquier tipo de información especial obtenida a través de imágenes digitales. La visión artificial la componen un conjunto de procesos destinados a realizar el análisis de imágenes. Estos procesos son: captación de imágenes, memorización de la información, procesado e interpretación de los resultados [Salas,2004]. La visión artificial utiliza la tecnología de IA más recientes para dotar a los equipos la capacidad de ver y analizar las tareas de fabricación inteligente, control de calidad y seguridad de los trabajadores [Galushkin,2007]. Las redes neuronales artificiales, o mejor conocidas como ANN por sus siglas en inglés, Artificial Neural Networks, son un método de resolver problemas, para aquellas tareas de clasificación, identificación, diagnóstico, optimización o predicción en las que el balance datos/conocimiento se inclina hacia los datos y donde, adicionalmente, puede haber la necesidad de aprendizaje en tiempo de ejecución y de cierta tolerancia a fallos. En estos casos las ANN se adaptan dinámicamente reajustando constantemente los “pesos” de sus interconexiones Las ANN se basan en la analogía que existe en el comportamiento y función del cerebro humano, en particular del sistema nervioso, el cual está compuesto por redes de neuronas biológicas que poseen bajas capacidades de procesamiento, sin embargo, toda su capacidad cognitiva se sustenta en la conectividad de éstas [Savaktar,2012].

Trabajos Relacionados

Existen varios proyectos que emplean redes neuronales artificiales y sistemas de visión artificial para lograr resolver diferentes problemas en un amplio rango de campos. Un grupo de investigadores de Lincoln Laboratory desarrollo un sistema de visión para el reconocimiento general de imágenes por medio de la detección de los bordes auxiliados por una red neuronal. El objetivo de este desarrollo era generar una estructura neuronal que pudiera ser aplicada para reconocer diferentes tipos de objetos con el mínimo posible de modificación al algoritmo. En 1998 en la Universidad de Georgia (University of Georgia) se desarrolló un sistema para la clasificación de la calidad de los huevos, mediante un sistema de visión de color y una red neuronal artificial. El sistema era capaz de detectar huevos de grado A y huevos con manchas de sangre. El sistema era muy sensible cuando se presentaban otras características como rajaduras en los huevos o suciedad, sin embargo, el grado de exactitud del sistema excedía los requerimientos [Valencia,2007]. También se han utilizado las RNA y visión artificial para la detección de rostros. Un grupo de colegiados de la universidad Carnegie Mellon desarrollaron un sistema basado en múltiples redes neuronales para mejorar el desempeño obtenido al utilizar una sola red neuronal. Uno de los mayores retos que se encontraron en este sistema fue encontrar el conjunto de imágenes sin rostros para entrenar el sistema y que este se comportara apropiadamente [Patel,1998]. En International Journal of Engineering and Innovative Technology (IJEIT) se publicó en marzo del 2012 un artículo de identificación y clasificación de frutas a granel usando redes neuronales. El sistema fue probado con 5 frutas diferentes; 6 manzana, zapote, mango, naranja y limón. Se utiliza una red de propagación hacia atrás comparando las características de color y de textura [Patel,1998]. En la universidad de Tarbait Modares de Irán, se desarrolló un sistema de visión artificial capaz de caracterizar la miel basándose en el color y una correlación con ciertos atributos químicos. Se utilizó una red neuronal artificial para transformar los valores RGB de las imágenes y predecir las concentraciones de cenizas, antioxidantes, etc. Con este sistema se obtuvo un alto grado de desempeño y se demuestra una alternativa viable para la caracterización de la miel con una prueba no destructiva [Savaktar,2012].



Materiales y métodos

El programa utiliza una red neuronal previamente entrenada para identificar los colores deseados. La red utilizada es una red feed-forward multicapa de perceptrones, entrenada con el algoritmo de aprendizaje de propagación hacia atrás, backpropagation, utilizando una librería de uso libre de AForge.

Los pasos que lleva a cabo el programa para inspeccionar el empaque o pieza son explicados a continuación, y su flujo está representado en el diagrama expresado en la Figura 1.

1. Adquirir imagen: En este paso se obtiene la imagen a analizar a través de una webcam por el mismo programa.
2. Procesar imagen: Dado que el programa inspecciona dos paquetes a la vez con una sola foto, se recorta la imagen original para obtener dos imágenes correspondientes a cada paquete.
3. Comparar pixeles con Red Neuronal: Debido a que la parte de interés no tiene una posición fija, se recorre la imagen completa en su búsqueda, comparando la información de cada píxel con la red neuronal.
4. Comparar resultados con parámetros de aceptación: Al terminar de comparar el ultimo píxel de la imagen, se realiza un conteo de pixeles encontrados para determinado color, y se compara con el parámetro de mínimo de pixeles deseados, para poder determinar si la parte de interés está presente o no en la imagen.

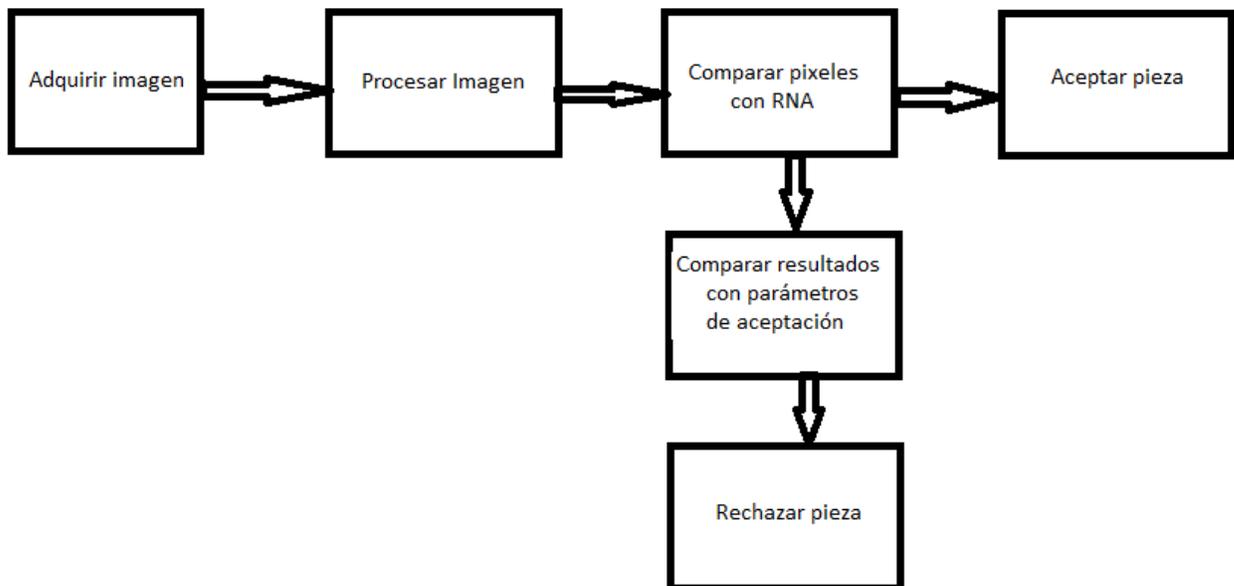


Figura 1. Diagrama general de la inspección del programa

En la interface de inspección podemos conectar a un PLC, controlador lógico programable, o trabajar con imágenes previamente grabadas en la computadora. La Figura 2 muestra la pantalla trabajando en modo simulación con imágenes previamente capturadas durante una corrida en producción conectado al PLC.



Se pueden apreciar dos imágenes con un signo de interrogación, que pertenecen al estado inicial del resultado de la inspección de cada uno de los paquetes respectivamente, así como un botón “Inspeccionar” que nos permite simular la señal de disparo que sería obtenida del PLC.

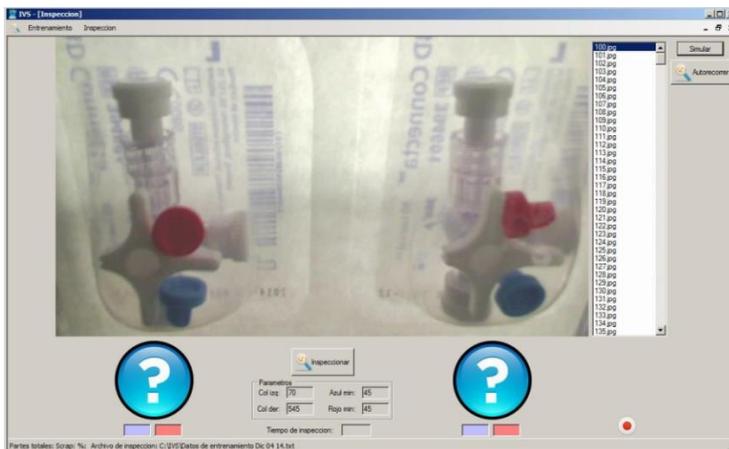


Figura 2. Interface de inspección en modo simulación.

En la Figura 3, se muestra la interface de inspección en línea, donde a la derecha se encuentra el recuadro de los parámetros de conexión al PLC por medio de Ethernet, y se especifica la etiqueta que actuará como señal de disparo de la inspección. En el centro se encuentran los parámetros de inspección, ver figura 4, los cuales contienen la información de la posición donde inicia la imagen del paquete de la izquierda, Col izq, y la posición donde inicia la imagen del paquete de la derecha, Col der. También se cuenta con los valores mínimos de aceptación para la detección de la parte azul, Azul min, y para la parte roja, Rojo min. El campo de tiempo de inspección muestra el tiempo que le tomó al programa inspeccionar ambas imágenes.

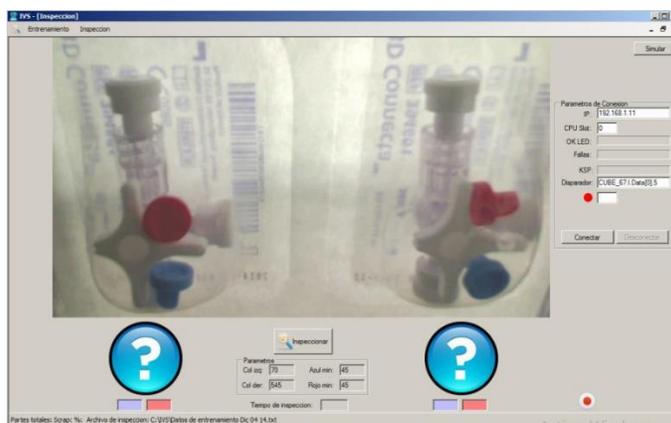


Figura 3. Interface de inspección en línea



Parámetros			
Col izq:	<input type="text" value="70"/>	Azul min:	<input type="text" value="45"/>
Col der:	<input type="text" value="545"/>	Rojo min:	<input type="text" value="45"/>
Tiempo de inspeccion:		<input type="text"/>	

Figura 4. Parámetros de inspección.

Configuración y entrenamiento del programa

Para obtener esta información se cuenta con la interface de entrenamiento, figura 5, la cual cuenta con la opción de adquirir una imagen proveniente del video capturado por la webcam, para posteriormente definir los parámetros necesarios para el correcto procesamiento y análisis de la imagen. Los pasos que sigue este proceso son:

1. Primeramente, se captura la foto correcta con la que se desea trabajar, pulsado el botón “Capturar”, lo que congelará la imagen.
2. Al capturar la imagen, se habilitan las opciones para señalar los puntos donde comienza la imagen de la izquierda y donde comienza la imagen de la derecha, los cuales podemos definir mediante los botones “Corte Izq” y “Corte Der” respectivamente. Al hacer click en la posición deseada, se dibujará un recuadro señalando el área de interés que se ha seleccionado.
3. En el centro se muestra los parámetros que serán guardados en el archivo y que representan la posición inicial de las imágenes en el eje x e y. Al estar conformes con la selección de las áreas, se realizan los recortes dados con el botón “Procesar Recortes”, y de forma automática el sistema tendrá la información que necesita para el entrenamiento.



Figura 5. Interface de entrenamiento.



Toma de muestras de colores

Ahora se deben tomar muestras de los colores que se desean enseñar a la red neuronal para lograr que esta diferencie apropiadamente los colores. Para este modelo, se han tomado 3 neuronas de entrada que corresponden cada una a los valores RGB, rojo, verde y azul, que componen los colores y solo 1 neurona de salida que nos indica si el color es rojo, azul, o pertenece al entorno en sí, y una capa oculta de 20 neuronas, Figura 6.

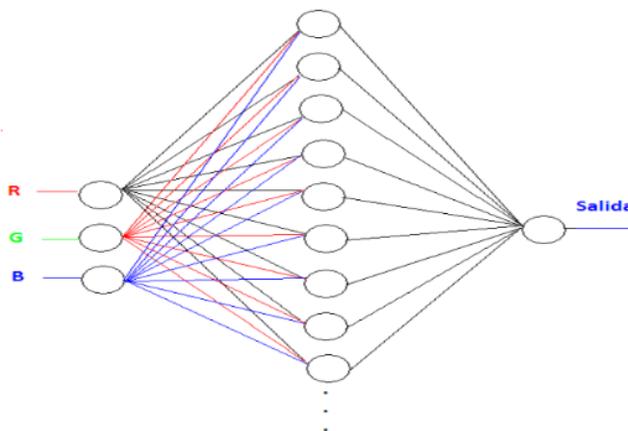


Figura 6. Estructura de red neuronal utilizada.

Las muestras del entorno ayudan a enseñarle al sistema los demás colores presentes en la imagen para que pueda diferenciar apropiadamente dichos colores, azul y el rojo, que se desean identificar. De no hacerlo de esta forma, la red neuronal interpretaría que ciertos colores del entorno bien podrían ser un azul o un rojo. Un ejemplo de esto se muestra en la Figura 7, donde se muestra el resultado de cuando solo se ha entrenado la red neuronal con azul y rojo y se han omitido las muestras de los colores del entorno, comparada con una red neuronal con datos del entorno.

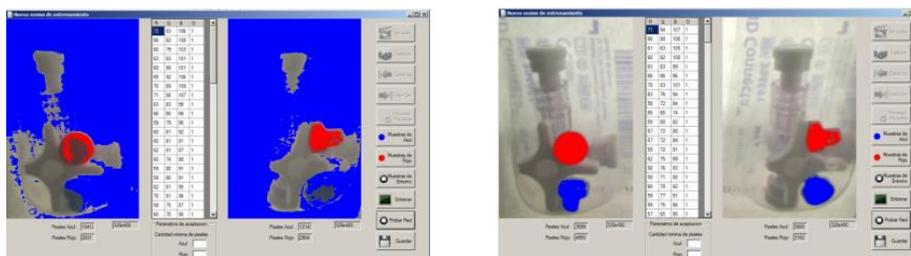


Figura 7. Desempeño de la ANN sin las muestras del entorno, izquierda, y con muestras del entorno, derecha.

Resultados y Discusión

El sistema fue instalado en la línea de producción, figura 8, mediante un protocolo de validación de desempeño de proceso, PQ, process quality, que consistió en utilizar el sistema de inspección durante un turno completo, para demostrar cuatro puntos principales:

1. Es capaz de detectar los paquetes que vayan incompletos



2. No genera más de 1% de falsos rechazos
3. No incrementa el tiempo de ciclo de la máquina
4. No genera tiempo caído

La máquina donde el sistema fue instalado pertenece al área de Stopcocks, y trabaja sobre un horario de 7 a.m. a 3:30 p.m. de lunes a viernes. El tiempo efectivo de producción del equipo está considerado en 7.5 horas, debido a los descansos y comidas del día.



Figura 8. Instalación del sistema de visión

El tiempo de ciclo del equipo actual es de 2 segundos aproximadamente, dando un total de 15 ciclos por minuto y un total de 30 partes por minuto debido a que la máquina inspecciona 2 partes a la vez. El sistema se puso a prueba en producción durante el turno completo, en el cual se fabricaron 14,576 piezas, dando un total de 32.39 partes por minuto. Es normal en este equipo que corra a un ritmo superior al de diseño y al requerimiento de producción, por lo que esta información fue suficiente para demostrar que la inspección no incrementa el tiempo de ciclo y no impacta a la producción. La figura 9 muestra el tiempo que ocupa para realizar la inspección, corroborando así que el tiempo de ciclo es menor a los 2 segundos que ocupa la máquina en general.

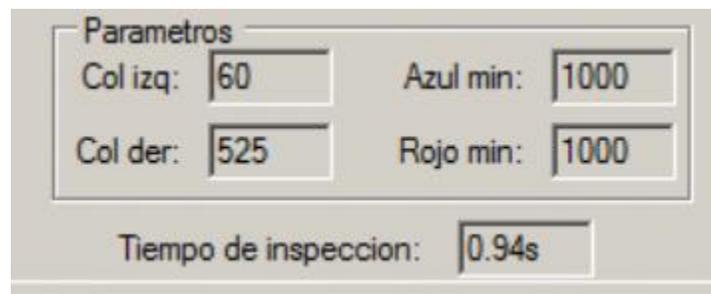


Figura 9. Tiempo de inspección

El tiempo promedio de ciclo es de 0.95 segundos, por lo que el tiempo de cada inspección es de 475 milisegundos, un tiempo similar al que tomaría un equipo de visión comercial utilizado en la línea de producción. Al final de turno, el equipo había realizado 7,288 ciclos, para un total de 14,576 partes inspeccionadas, de las cuales solo 4 partes fueron rechazadas. Dos de las partes rechazadas fueron por faltante de componente rojo, y las otras dos partes fueron por faltante de componente azul. El sistema no generó ningún falso rechazo por lo que se cumplió fácilmente con el requerimiento de menos de 1% de falsos



rechazos. Al término del turno, el material producido pasó al área de calidad, donde fue inspeccionado 100% para verificar que el sistema de visión no dejó ir ningún paquete incompleto. Los resultados por parte de calidad corroboraron y certificaron que el sistema funcionó adecuadamente al identificar los paquetes incompletos. De igual manera, durante el turno se guardaron las imágenes de todas las piezas inspeccionadas y se revisó manualmente el desempeño utilizando el simulador con cada una de las piezas. El sistema rechazó exactamente las mismas piezas, y detectó perfectamente los componentes en cada uno de los paquetes.

Conclusiones

Tomando en cuenta los resultados obtenidos durante la corrida de producción bajo el protocolo de validación de desempeño de proceso, se demuestra que la red neuronal con la ayuda de visión artificial es capaz de resolver el problema que se ha presentado de una excelente manera. De no emplear una red neuronal, la detección del color mediante un algoritmo convencional se complica con las variaciones del tono causadas por la orientación e iluminación, resultando en un sistema más complejo de programar y menos eficiente. Se demuestra que bajo este concepto de inspección se logra omitir en el desempeño todas las variables que podrían afectar a un sistema de visión convencional comercial, como lo son:

1. Variación en la iluminación
2. Orientación de las partes a inspeccionar
3. Ubicación de las partes a inspeccionar dentro del área de interés
4. Variación del color debido a la geometría/forma de la parte de interés
5. Cambios en el enfoque
6. Reflejos en el plástico de empaque
7. Transparencia del plástico por el que se debe verificar el empaque

A pesar de los buenos resultados y un tiempo de ciclo decente, se realizaron otras pruebas con las imágenes capturadas para mejorar el tiempo de ciclo de la inspección. Originalmente, las imágenes capturadas son inspeccionadas en una resolución de 320x480 pixeles de cada paquete, y se modificó para trabajar con una resolución de 60x110 pixeles, reduciendo el tiempo de ciclo de .95 segundos o 950 milisegundos, a tan solo .06 segundos o 60 milisegundos promedio, volviendo el sistema 15.83 veces más rápido.

Bajo este nuevo tiempo de ciclo de alta velocidad, el sistema puede ser empleado para inspeccionar hasta 30 piezas por ciclo y se está pensando en probarlo en una máquina de la misma área que trabaja 8 paquetes por ciclo, quedando aun sobrado el sistema en cuestión de velocidad. El desempeño en cuestiones de calidad no se vio afectado con la nueva resolución, y se rechazaron las 4 piezas faltantes de componentes tal como con la resolución original.

Referencias

1. <http://www.etitudela.com/celula/downloads/visionartificial.pdf>
2. <https://www.intel.es/content/www/es/es/manufacturing/what-is-machine-vision.html>
3. Salas, R. (2004). Honey characterization using computer vision system and artificial neural networks. 159. Savaktar, D. (2012).Redes Neuronales Artificiales. Universidad de Valparaiso. Departamento de computacion. 116.



4. Galushkin, A. (2007). Neural networks for control systems. IEEE Transactions.. Neural Networks Theory. Springer.
5. Gestal Pose, M. (2000). Introduccion a las redes de neuronas artificiales. Departamento de Tecnologías de la Información y las Comunicaciones Universidad de Coruña.
6. Henry A. Rowley, S. B. (1998). Introduction to neural networks for C#. Heaton Research, Inc. Neural Network-Based Face Detection.
7. Rosario. Murata, N. Y. (1992). Redes Neuronales: Conceptos Básicos y Aplicaciones. Informática Aplicada a la Ingeniería de Procesos – Orientación I. Universidad Tecnológica Nacional – Facultad Regional
8. Robert L. Harvey, P. N. (1991). Network information Criterion - determining the number of hidden units for an artificial neural network model. IEEE.
9. Rocha Miranda, A., & Morales Ramos, J. C. (2004). A Neuronal Network Architecture for General Image Recognition. The Lincoln Laboratory Journal, 4(189).
10. Rojas, R. (1996). Procesamiento digital de señales y redes neuronales. Obtenido de Consultoría y capacitación para la competitividad de clase mundial: http://www.icicm.com/files/ProcDigitalSe_alesRedesNeuronales.doc
11. Sahameh Shafiee, S. M.-C. (2014). Neural Networks: A Systematic Introduction. Berlin: Springer.
12. V. C. Patel, R. W. (1998). Identification and Classification of Bulk Fruits Images using Artificial Neural Networks. International Journal of engineering and Innovative Technology, 1(3).
13. Valencia Reyes, M. A. (2007). Color Computer Vision and Artificial Neural Networks for Detection of Defects in Poultry Eggs. Artificial Intelligence Review(163-176).
14. Velez Serrano, J. F., Moreno Diaz, A. B., Sanchez Calle, A., & Sanchez-Marin, J. L. (2003).
15. Algoritmo Backpropagation para redes neuronales: conceptos y aplicaciones. Instituto Politecnico Nacional. Centro de investigacion en computacion.
16. José Francisco Vélez Serrano. Vision Artificial. (s.f.). Recuperado el 10 de 10 de 2014, de C.I.P. ETI Tudela: www.etitudela.com/celula/downloads/visionartificial.pdf White, H. (1992).
17. Zadeh, L. A. (1973). Artificial Neural Networks: Approximation and learning theory. Basil, Blackwell: Oxford. Outline of a New Approach to the Analysis of Complex Systems and Decision Processes. 24-44.

