

## Metodología de ayuda a la decisión para el plan de producción en sistemas de manufactura flexible

---

Oscar Báez Senties

*Instituto Tecnológico de Orizaba  
Departamento de Ingeniería Industrial  
Orizaba, Veracruz, México  
[obaez70@yahoo.com.mx](mailto:obaez70@yahoo.com.mx)*

Raúl Torres Osorio

*Instituto Tecnológico de Orizaba  
Departamento de Ingeniería Industrial  
Orizaba, Veracruz, México  
[raultorresosorio@yahoo.com.mx](mailto:raultorresosorio@yahoo.com.mx)*

Ana María Alvarado Lassmann

*Instituto Tecnológico de Orizaba  
Departamento de Ingeniería en  
Sistemas Computacionales  
Orizaba, Veracruz, México  
[lassmann@prodigy.net.mx](mailto:lassmann@prodigy.net.mx)*

Fernando Ortiz Flores

*Instituto Tecnológico de Orizaba  
Departamento de Ingeniería Industrial  
Orizaba, Veracruz, México  
[fer\\_chi\\_lo@yahoo.com.mx](mailto:fer_chi_lo@yahoo.com.mx)*

Constantino Gerardo Moras Sánchez

*Instituto Tecnológico de Orizaba  
Departamento de Ingeniería Industrial  
Orizaba, Veracruz, México  
[t\\_moras@yahoo.com.mx](mailto:t_moras@yahoo.com.mx)*

---

### Resumen

El artículo presenta alternativas para mejorar el proceso de planeación de la producción, de manera provisoria. El principal inconveniente es a menudo el tiempo para lograr una « buena » planeación, en relación al tiempo del que disponen las personas responsables de la producción. Este tiempo puede variar dependiendo de la magnitud del problema, del equipo de cómputo disponible, etc. La literatura al respecto pone en evidencia un tiempo de cálculo elevado a causa del uso excesivo del simulador, en cuanto a la fase de evaluación de los indicadores de producción. En este sentido y tomando en cuenta la complejidad del problema, se presenta un estudio basado en la combinación de la simulación y los métodos de inteligencia artificial, los cuales han permitido obtener resultados satisfactorios para el problema de planeación de la producción a corto plazo.

### Palabras clave

Simulación, Redes Neuronales, Algoritmos Genéticos, Optimización

## **Introducción**

Para el desarrollo sistemático de una herramienta de ayuda a la decisión, la acción a tomar consiste en utilizar un modelo de fabricación simple representado por un simulador que a su vez pueda reproducir los fenómenos intrínsecos del sistema.

En este sentido se ha considerado utilizar los modelos de redes neuronales tomando en cuenta para el aprendizaje un modelo de simulación con miras a la optimización. El programa de simulación se desarrolló en nuestro laboratorio y sirvió de soporte para el presente estudio. Asimismo, este estudio permite el análisis de los criterios a considerar para evaluar el rendimiento del modelo. Esta fase permite poner en evidencia las variables del responsable de producción frente a los criterios establecidos (Charles, et al. 2000).

El desarrollo de los modelos de redes neuronales tiene como objeto representar el comportamiento del sistema de acuerdo a los criterios considerados. Por otro lado, el análisis debe tomar en cuenta el aspecto de múltiples criterios, que es común en este tipo de problemática. El objetivo del estudio es ayudar al responsable de producción a la toma de decisiones al encontrar mejores soluciones para la planeación de la producción y proponer métodos o herramientas que permitan progresos en la solución de problemas de decisión en donde los diferentes puntos de vista, a menudo contradictorios, deben ser tomados en cuenta.

Dadas las consideraciones presentadas con anterioridad sobre el problema de concepción de sistemas de fabricación flexible, se utilizan algoritmos genéticos multicriterio. Las soluciones obtenidas pueden ser simuladas de forma detallada por un simulador con el fin de anexarlas a la base de datos original. Un ejemplo de una pequeña fábrica en el que se reproduce fidedignamente el proceso global de la fabricación de componentes electrónicos sirve de base en este estudio.

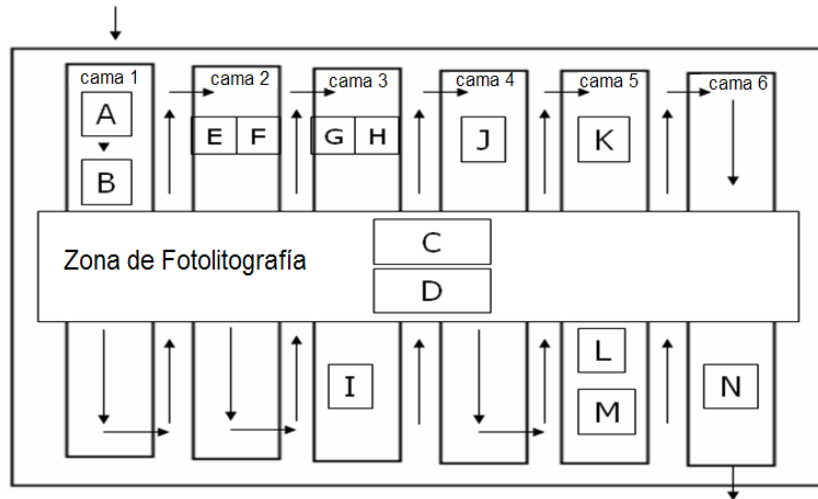
## **Metodología**

Debido principalmente a la exposición del medio ambiente, las plaquetas de silicio (materia prima de los semiconductores), pueden contaminarse durante el manejo habitual de los productos. Es por ello, que uno de los principales objetivos en la industria de semiconductores es la reducción del inventario en proceso, para contribuir con los indicadores de productividad de la empresa. Cabe mencionar que la inversión de equipo y maquinaria en este sector industrial es considerablemente alta (Charles, 2000).

### **Descripción de la fábrica**

La fábrica de componentes electrónicos está representada en la figura 1. Ésta reproduce las características de una fábrica real, la cual contiene 14 equipos de los cuales 12 son diferentes (Peyrol, 1992). La fabricación comprende 24 etapas, los equipos C y D son utilizados en varias ocasiones, en algunos casos, hasta de 6 veces para la fabricación de un producto.

Los equipos E y F, así como G y H son equipos que trabajan en paralelo pudiendo efectuar la misma operación. Esta fábrica debe asegurar una producción entre 2 y 4 productos de diferente tipo. El número de lotes considerados corresponde a una producción total comprendida entre 20 y 100 lotes.



**Figura 1.** Estructura de la fábrica de componentes electrónicos

La variedad es una de las características de un sistema de fabricación por lotes, este es el caso en la industria de los semiconductores. La tabla 1 uno describe las etapas del proceso de producción, así como los tiempos de fabricación para cada producto.

Etapa	Zona	Equipo	Capacidad [lotes]	Tiempo de procesamiento para cada producto			
				Producto 1 [min]	Producto 2 [min]	Producto 3 [min]	Producto 4 [min]
1	Difusión	A	1	120	120	120	120
2	Difusión	B	4	0	0	1000	700
3	Fotolitografía	C	1	0	0	20	20
4	Grabado	D	1	0	0	15	15
5	Difusión	E	2	500	200	500	400
6	Difusión	F	2	500	200	500	400
7	Fotolitografía	C	1	20	20	20	20
8	Grabado	D	1	15	15	15	15
9	Difusión	G	2	700	600	500	700
10	Difusión	H	2	700	600	500	700
11	Fotolitografía	C	1	20	20	20	0
12	Grabado	D	1	15	15	15	0
13	Prueba	I	1	1	1	1	1
14	Difusión	J	2	350	400	500	0
15	Fotolitografía	C	1	0	0	0	30
16	Grabado	D	1	0	0	0	20
17	Difusión	K	2	0	0	0	400
18	Fotolitografía	C	1	30	30	30	30
19	Grabado	D	1	20	20	20	20
20	Grabado	L	1	140	180	200	0
21	Metal	M	1	120	120	120	120
22	Fotolitografía	C	1	20	20	20	20
23	Grabado	D	1	20	20	20	20
24	Metal	N	1	20	20	20	20

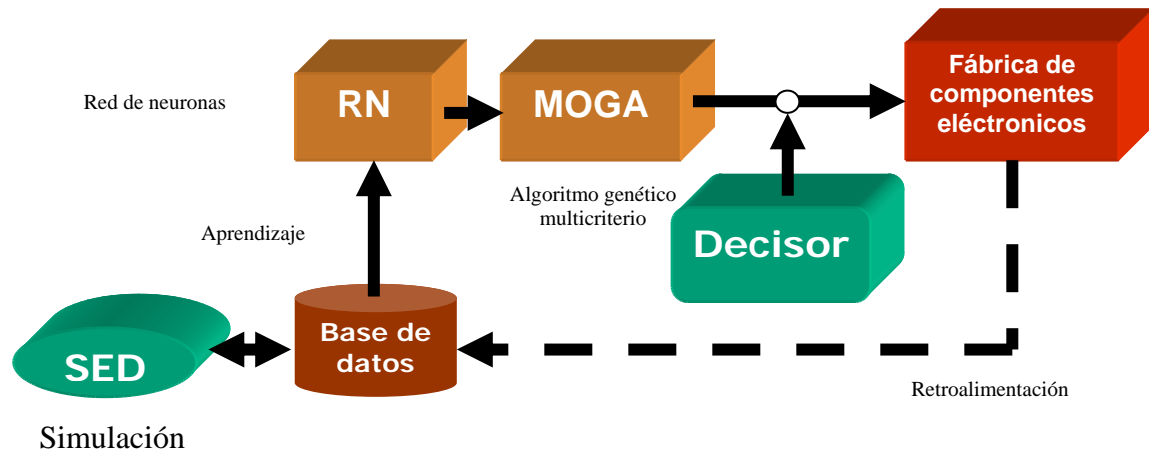
Nota : 1 lote = 50 placas de silicón

**Tabla 1.** Tiempos de procesamiento por etapas y productos

### Descripción general de la metodología

En la figura 2 presenta la secuencia de las herramientas empleadas en el presente estudio. Es necesario crear una base de datos generada por medio de un modelo de

simulación, el cual debe representar adecuadamente el sistema de fabricación. Posteriormente, la información de la base de datos es utilizada para crear, por medio de los métodos de aprendizaje (Sung, 1999), diferentes redes de neuronas (una para cada criterio). En esta etapa es posible comparar los resultados del simulador, con los arrojados por las diferentes redes de neuronas. Las funciones no lineales de cada red pueden ser utilizadas en la optimización multicriterio, por medio de un algoritmo genético multicriterio. Finalmente, los resultados obtenidos sirven de ayuda a la decisión para el responsable de la planeación de la producción. Los resultados de la aplicación de esta metodología, pueden ser retroalimentados directamente a la base de datos para una constitución más robusta de la misma.



**Figura 2.** Metodología de ayuda a la decisión

### Consideraciones en la metodología

La metodología de modelado y diseño para aplicaciones en planeación de la producción está basada en el desarrollo de un sistema de inteligencia artificial (IA) de ayuda a la decisión. A continuación se mencionan algunas consideraciones pertinentes en la aplicación de las técnicas.

### Modelo de simulación

MELISSA (*Micro-Électronique : Logiciel Industriel de Simulation et de Suivi d'Ateliers*) fue el programa utilizado para crear el modelo de simulación. En 1992 fue creado, por el equipo *Conception Optimale et Ordonnancement de Procédés* perteneciente al equipo de *Laboratoire de Génie Chimique* (UMR CNRS 5503) y con la colaboración con la sociedad MOTOROLA en Toulouse, Francia.

La simulación del proceso de fabricación considera las asignaciones en las operaciones de las máquinas y las rutas de cada producto dentro de la fábrica. Esta técnica se ha empleado ampliamente en la fabricación de semiconductores (Min et al., 2003).

Las corridas del simulador permiten identificar las variables más sensibles en algunos criterios, como el tiempo de espera, el porcentaje de utilización del equipo, la limitación del inventario en proceso, etc. Fue necesario definir las variedades de productos así como sus volúmenes de producción. De igual manera los tiempos entre llegadas de los lotes (TELL), son considerados como variables de decisión. Para TELL, se realizó un muestreo que permitió obtener datos, los cuales fueron sometidos a pruebas estadísticas de bondad de ajuste. TELL se ajustó a una distribución normal con un media de 203 minutos y una desviación estándar de 31 minutos. El número de

corridas finales fue estipulada en 2250 (Averill, 2000). Las consideraciones del modelo se mencionan a continuación:

1. Los equipos y maquinaria están disponibles durante toda la simulación y no se consideró el mantenimiento preventivo.
2. La fábrica trabaja tres turnos los siete días de la semana.
3. La fabricación es por lotes, los cuales tiene el mismo tamaño (50 plaquetas).
4. Los niveles iniciales de almacenamiento de material no son suficientemente importantes para generar restricciones de disponibilidad.
5. Todos los lotes se asignan a cada tipo de producto y se manejan bajo la misma regla de prioridad, FIFO.
6. Como variable de demanda, el porcentaje de cada familia de productos fue considerado en 12.5%, 25% o 37.5%.
7. Las cantidades de productos y piezas almacenadas son consideradas transacciones en unidades de lote.
8. Los equipos en paralelo son idénticos en todos los aspectos.
9. Se toma en cuenta el tiempo de carga y descarga de las máquinas.
10. Los operadores no fueron considerados en el modelo.

### **Base de Datos (BdD)**

Como ya se mencionó, la base de datos fue generada por el simulador, el cual representa las características reales de un sistema. Las funciones multicriterio fueron definidas en base a aquellas ligadas a los productos, así como aquellas relacionadas con los equipos de fabricación.

### **Red de neuronas artificial (RNA)**

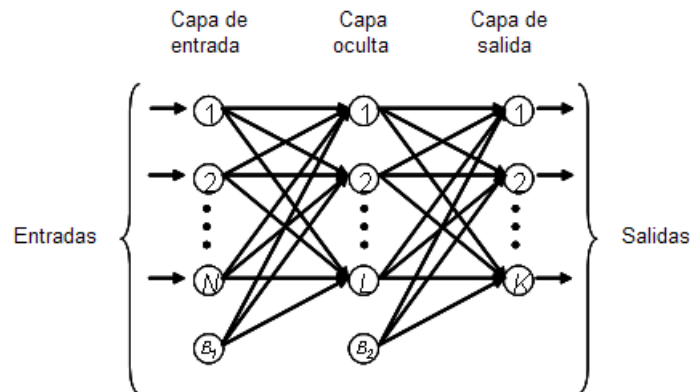
La red de neuronas multicapas es el algoritmo empleado en este estudio. El perceptrón multicapas es una red compuesta de  $L$  capas y cada neurona se encuentra conectada a las neuronas de la capa siguiente. Cada neurona  $K$  es una conexión en donde se produce el efecto de una función de transferencia de tipo sigmoideal. La topología de una red clásica está compuesta de varias capas de neuronas. La figura 3 muestra el esquema de una red de neuronas artificial.

- Una capa de entrada que representa las entradas de donde son transmitidos las variables.
- Una o varias capas ocultas efectúan el tratamiento específico de la red.
- Una capa de salida que proporciona los resultados.

Con este enfoque, el software Matlab, el cual contiene un módulo consagrado al desarrollo de redes neuronales, es utilizado. La red de neuronas almacena información en una cadena de interconexiones neuronales por medio de los pesos. La función de transferencia utilizada es la tangente hiperbólica, su desempeño es como función de activación para las capas ocultas y de salida. Generalmente los datos de entrada deben sufrir una normalización apropiada, con el fin que todas las variables tengan la misma influencia estadística en la red (Howard, 2000).

Una arquitectura de diferentes tipos de redes de neuronas artificiales (RNA) fue explorada, con el objetivo de encontrar el diseño idóneo al problema que debemos resolver. Una etapa de aprendizaje debe ser considerada para la creación de un modelo neuronal. La fase de aprendizaje se utiliza para ajustar los pesos, los cuales inicialmente son valores aleatorios. El valor del error promedio cuadrado (MSE por sus siglas en inglés) sirve para aplicar la corrección de pesos en cada iteración.

Finalmente, las diferentes redes “aprenden el comportamiento” de la base de datos generada con el simulador.



**Figura 3.** Red de neuronas

### Algoritmo genético multicriterio (AGM)

Debido a que la mayoría de los problemas que se presentan en el mundo real son de tipo multiobjetivo, existe una ventaja considerable al utilizar métodos meta-heurísticos, como los algoritmos genéticos. Éstos pueden calcular, simultáneamente, varios criterios durante el proceso de optimización. La elección de un algoritmo genético (AG) para la optimización fue contemplada dentro de un marco de funcionamiento multicriterio. En esta etapa, un acoplamiento de ambos sistemas de inteligencia artificial proporciona los avances para el prototipo de la metodología. Combinando previamente las redes de neuronas en el algoritmo genético, es posible encontrar el Pareto óptimo (Dietz, 2004) en las diferentes zonas de soluciones. El AGM es desarrollado en código C<sup>++</sup>. La población inicial constituye un punto básico de partida, en la medida que evoluciona cada generación para encontrar individuos más aptos.

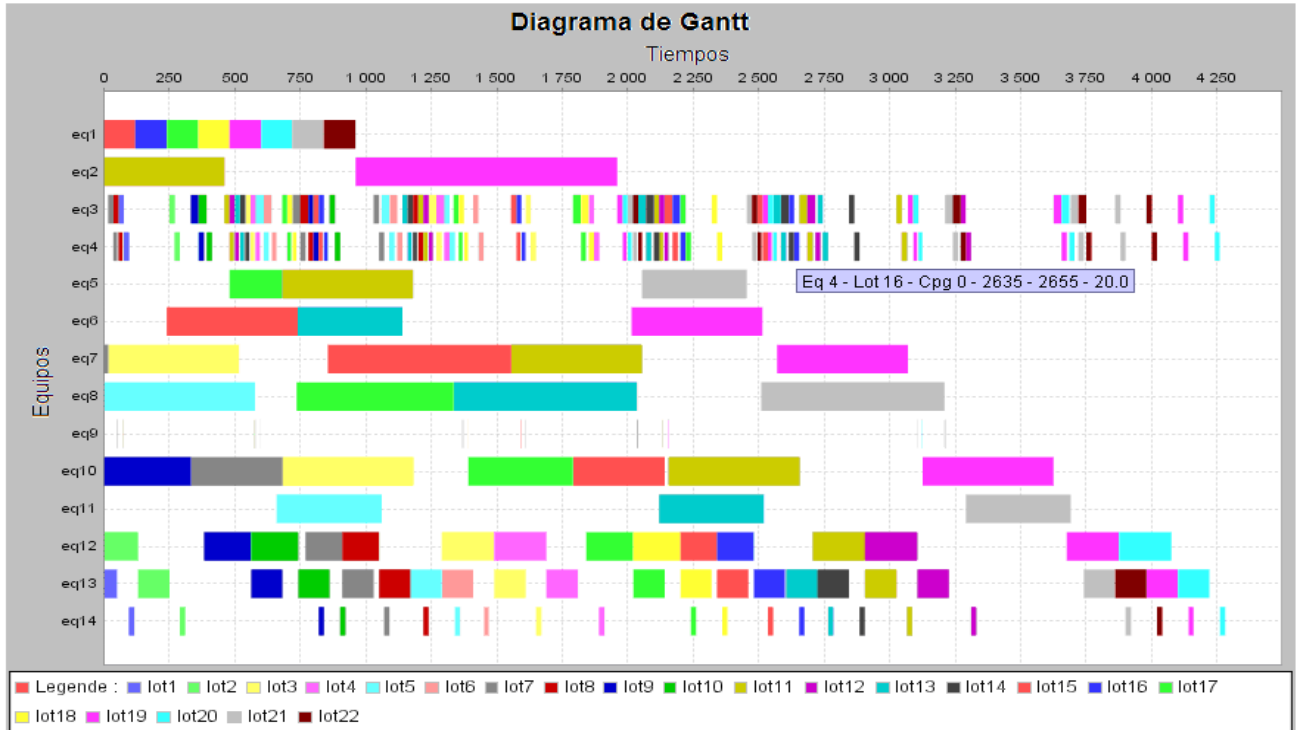
Se utiliza el cruzamiento aleatorio de cromosomas. Este método tiene la ventaja de proporcionar una población variada, asegurando una buena cartografía en el espacio de búsqueda. Es importante determinar el tamaño de la población, como punto clave en la operación de los algoritmos genéticos. Una población demasiado pequeña, no podrá evolucionar adecuadamente. Una población demasiado grande, puede producir tiempos computacionales elevados. Fueron considerados los siguientes operadores genéticos:

1. Operador de Selección. La selección de los individuos más aptos se hace por medio de la ruleta de Goldberg (1994). Para cada criterio se utiliza una ruleta para la selección.
2. Operador de Cruzamiento. La combinación de cromosomas se lleva a cabo por el cruce clásico a 1 punto (Dietz, 2004).
3. Operador de Mutación. Este operador reemplaza aleatoriamente un cromosoma por el valor binario opuesto.
4. Operador de Elitismo. De cada generación se guarda la mejor solución para evitar la pérdida del individuo más competente.

Finalmente, una etapa de validación e implementación fue considerada para la retroalimentación y el auto aprendizaje del sistema.

## Resultados

Una vez llevada a cabo las simulaciones es posible observar el comportamiento del modelo. Algunos resultados obtenidos para los lotes y los equipos pueden observarse en el diagrama de Gantt (figura 4).



**Figura 4.** Gráfica de Gantt del proceso de fabricación

Los criterios considerados se explican a continuación. En el simulador, la tasa de utilización promedio de los equipos (TUM) fue calculada como:

$$TUM(\%) = \frac{\sum_{i=1}^E TU_i}{E} \times 100 \quad (1)$$

Donde,  $TU_i$  es la tasa de utilización por equipo  $i$  y  $E$  es el número total de equipos. El cálculo del tiempo promedio de permanencia (TSM) en el simulador MELISSA, se calculó de la siguiente manera:

$$TSM = \frac{\sum_{j=1}^S (DS - DE)}{S} \quad (2)$$

Donde,  $DE$  es el tiempo de entrada de lotes,  $DS$  es el tiempo de salida de lotes y  $S$  representa el número de lotes procesados. Una medida interesante de dispersión utilizada frecuentemente en la fabricación de semiconductores (Hyeung et al., 2003) es la desviación estándar del tiempo promedio de permanencia (EC).

El tiempo promedio de espera (*MTA*) de los productos fabricados fue considerado. Este criterio fue calculado de acuerdo a la fórmula

$$MTA = \frac{\sum_{j=1}^{TS} TTS_j}{TS} \quad (6)$$

Donde *TS* representa el número de veces que los productos tuvieron que esperar y *TTS* es el tiempo de espera de los mismos.

Tomando en cuenta los datos obtenidos se utilizó el programa de Matlab (Howard et al. 2000), para modelar las redes de neuronas. Se realizó una red de neuronas por cada criterio considerado (*TUM*, *EC* y *MTA*). El tipo de red utilizado fue la red de neuronas de retropropagación; las ecuaciones 3, 4 y 5 describen el cálculo para el modelo de RNA.

$$p_{ne} = x_{ne} \quad (3)$$

Donde,  $p_{ne}$  es el valor normalizado de los valores reales de las variables de entrada  $x_{ne}$ .

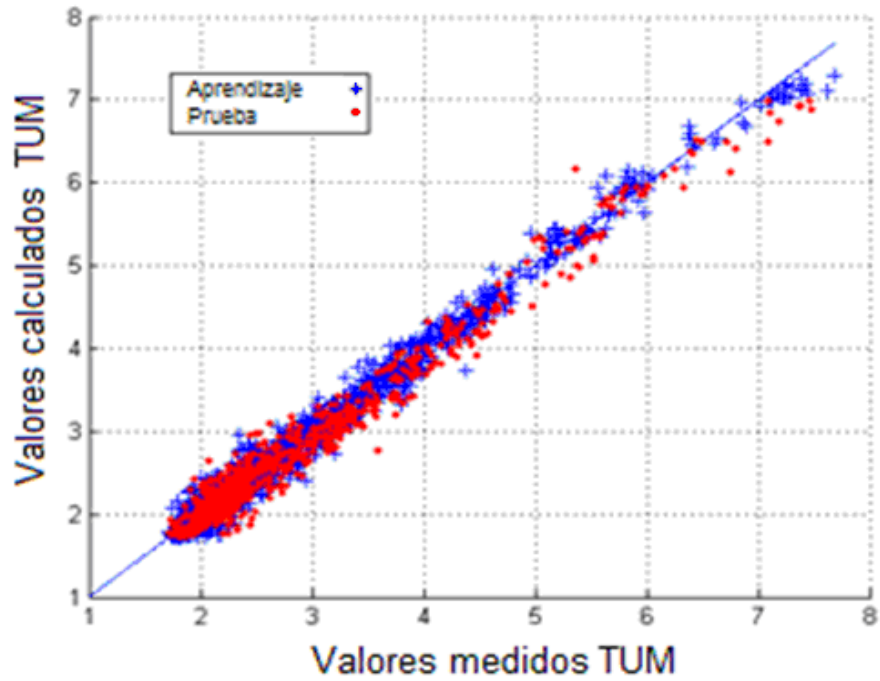
$$n_1 = \tanh \left[ \sum_{k=1}^m IW_k p_{ne} + b_1 \right] \quad (4)$$

La función de activación elegida fue la función tangente hiperbólica ( $\tanh$ ).  $n_1$  es el valor para la capa oculta,  $IW_i$  son los pesos iniciales de la capa oculta  $i$ ,  $b_1$  representa los valores de polarización de la capa oculta y  $nn$  es el número de neuronas.

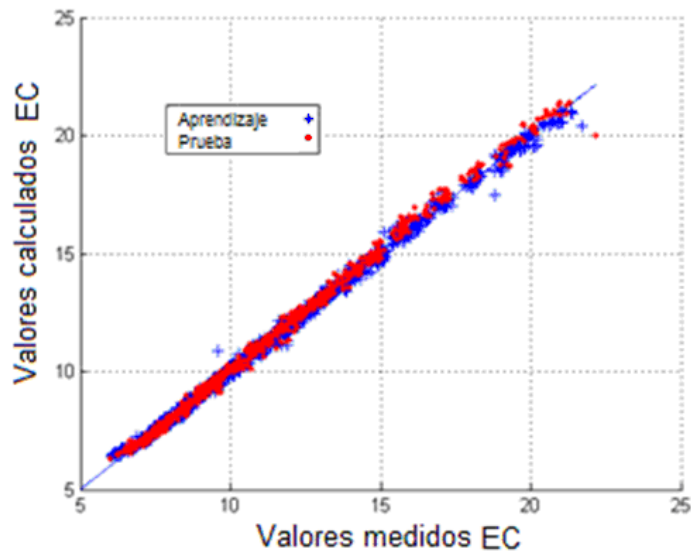
$$n_2 = \tanh \left[ \sum_{j=1}^{ns} LW_j n_1 + b_2 \right] \quad (5)$$

$n_2$  es el cálculo para la segunda capa,  $LW_j$  son los pesos finales de la segunda capa  $j$ ,  $b_2$  representa los valores de polarización de la capa de salida y  $ns$  es el número de neuronas de salida.

La base de datos fue modelada por medio de las redes de neuronas para la desviación estándar del tiempo promedio de permanencia (*EC*) y la tasa de utilización promedio de los equipos (*TUM*). Las figuras 5 y 6 muestran la comparación entre los valores calculados con el simulador y los valores obtenidos con las redes de neuronas.




**Figura 5.** Aprendizaje de la red de neuronas



**Figura 6.** Aprendizaje de la red de neuronas

Continuando con la metodología propuesta, las redes de neuronas fueron optimizadas por medio del algoritmo genético multicriterio. El funcionamiento detallado del AG multicriterio se encuentra en los trabajos de Azzaro-Pantel (1998) y Dietz (2004). Los parámetros utilizados fueron los siguientes: tamaño de la población 100, número de generaciones 250, tasa de supervivencia 0.5, la tasa de mutación 0.1 y el cruzamiento a un punto. Estos valores corresponden a los valores clásicos que es

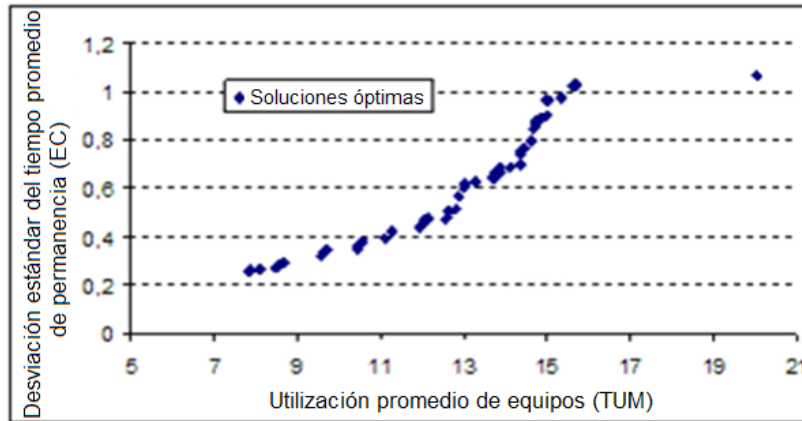
posible encontrar en el trabajo de Dietz. La figura 7 muestra la interacción entre las redes de neuronas y el algoritmo genético multicriterio.



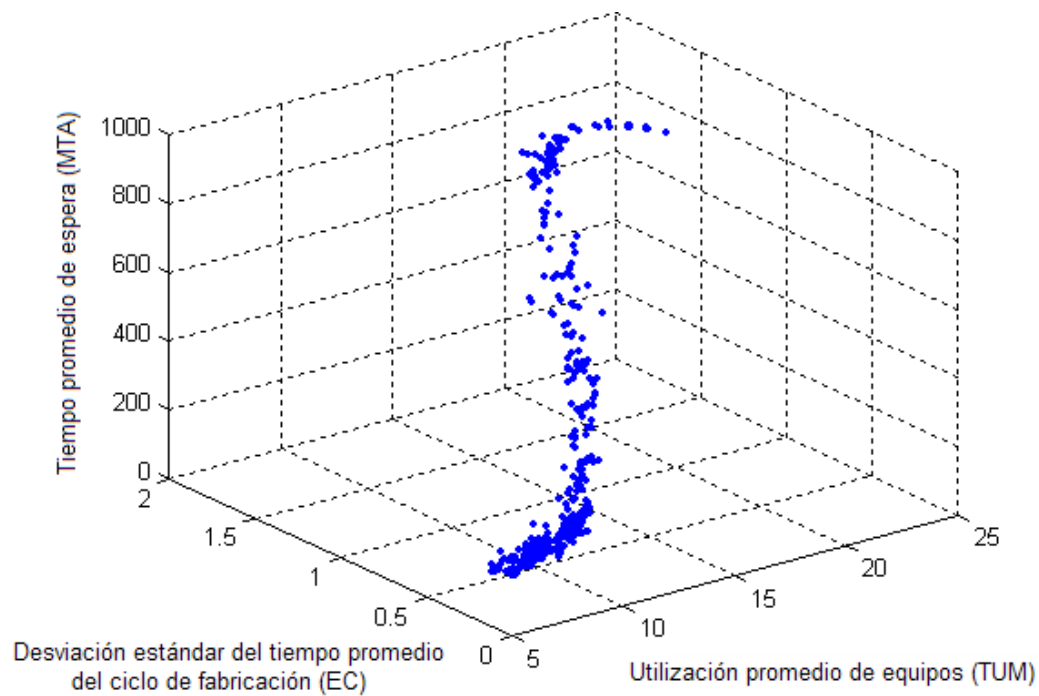
**Figura 7.** Algoritmo genético multicriterio

La figura 8 presenta los resultados después de la ejecución del AGM para el caso bicriterio en la minimización de la desviación estándar del tiempo promedio de permanencia (*EC*) y la maximización de la tasa de utilización promedio de los equipos (*TUM*). Todos los resultados son considerados factibles.

La metodología multicriterio permite añadir uno o más criterios para el estudio, por lo tanto se optó por incluir el minimizar el tiempo promedio de espera (*MTA*) de los productos fabricados, como un tercer criterio para su optimización. La figura 9 muestra el resultado obtenido de este proceso.



**Figura 8.** Soluciones óptimas bicriterio para *EC* y *TUM*



**Figura 9.** Soluciones óptimas tricriterio para *EC*, *TUM* y *MTA*

Para las figuras 8 y 9 el decisor puede elegir entre las soluciones óptimas, la más conveniente a los intereses inmediatos de la empresa. Esta herramienta se convierte entonces en un sistema de ayuda a la decisión, donde las variables consideradas presentan una complejidad razonable y donde el tiempo para la toma de decisiones es demasiado importante.

### Conclusiones del proyecto

En este estudio una metodología híbrida entre simulación, redes neuronales y algoritmos genéticos fue presentada como una herramienta de ayuda a la decisión para la fabricación de componentes electrónicos. Un ejemplo fue simulado considerando tres criterios: el tiempo promedio de espera (*MTA*), la desviación estándar del tiempo promedio del ciclo de fabricación (*EC*) y la utilización promedio de

equipos (*TUM*). Se utilizaron las redes de neuronas como técnica de modelación. Posteriormente, un algoritmo genético fue utilizado para optimizar las diferentes funciones objetivo para la planeación de la producción de una fábrica de componentes electrónicos.

Además, gracias a la red de neuronas, el tiempo de cómputo para realizar el cálculo se redujo considerablemente respecto a lo que necesita la simulación. Este método tiene la ventaja de proveer una estimación de los resultados prácticamente en tiempo real. Finalmente, la utilización de un algoritmo genético multicriterio ofrece la posibilidad de considerar otros criterios de interés.

### **Referencias Bibliográficas**

Abada, A. "Contribution a la résolution des problèmes d'ordonnement par réseaux de neurons", Thèse de doctorat Laboratoire d'Automatique de Grenoble - L.A.G - I.N.P.G, Novembre 1997.

Arisha, A. "Intelligent shop scheduling for semiconductor manufacturing", PhD thesis, Dublin City University, Ireland, 2003.

Averill M. L. y W.D. Kelton, *Simulation Modeling and Analysis*, 3/e, McGraw Hill, 2000

Azzaro-Pantel, C., L. Bernal-Haro, P. Baudet, S. Domenech, y L. Pibouleau, "A two-stage methodology for short-term batch plant scheduling: discrete-event simulation and genetic algorithm" *Computers and Chemical Engineering*, Vol. 22, #10, 1461-1481, 1988.

Báez Senties, O., *Méthodologie d'aide à la décision multicritère pour l'ordonnement d'ateliers discontinus*, PhD Thesis, INP Toulouse, France, (2007).

Billaut, J.C., y F. Roubellat "A decision support system for real time production scheduling " *LAAS – CNRS Report 92459*, 2001.

Charles, A.S., L. Rigolot, C. Pantel-Azzaro, y D. Jaume "Caractérisation des paramètres influant la performance d'ateliers discontinus en présence d'aléas", *Revue Internationale d'Ingénierie des Systèmes de Production Mécanique*, Décembre 2000.

Dietz, A. "Optimisation multicritère pour la conception d'ateliers discontinus multiproduits: aspects économique et environnemental", Thèse de doctorat, INP ENSIGC Toulouse, France (2004).

Goldberg, D.A., *Algorithmes génétiques*, Addison-Wesley, (1994).

González, C.A., G. Acosta, J. Mira, y C. Prada "Knowledge based process control supervision and diagnosis: the AEROLID approach" *Expert Systems with Applications*, Vol. 14, #3, 371-383, 1998.

Howard D. y B. Mark. *Neural network toolbox for use with MATLAB*, The Math Works, Inc., September 2000.

Hyeung, S., y Y. Yuehwern, "Development of a real-time multi-objective scheduler for a semiconductor fabrication system", Taylor & Francois Group, 2003.

Min, H.S., Y. Yih, y C.O. Kim. "Development of a real-time multi-objective scheduler for a semiconductor fabrication system", *International Journal of Production Research*, 41(10), 2345-2364, 2003.

Montagno, R., R.S. Sexton, y B.R. Smith, "Using neural networks for identifying organizational improvement strategies" *European Journal of Operational Research*, Vol. 142, #2, 382-395, 2002.

Peyrol E., *Gestion d'un atelier de fabrication de composants électroniques*, PhD Thesis, INP Toulouse, France, (1992)

Shenai, V.D. "A mathematical programming based procedure for the scheduling of lots in a wafer fab", Thesis, Master of Science in Industrial and Systems Engineering, Virginia Polytechnic Institute and State University (2001).

Sung, C.S., y Y.I. Choung "A neural network approach for batching decisions in wafer fabrication", *International Journal of Production Research*, 1999, Vol. 37, #13, 3101-3114.

Vargas, F.D., y V. De Rivera, "A model predictive control approach for real-time optimization of reentrant manufacturing lines" *Computers in Industry*, 2001, Vol. 45, #1, 45-57.