



Mejora en el diseño y control dimensional de un producto usando un método Neuro-Estadístico

Pedro Pérez Villanueva
Corporación Mexicana de Investigación en Materiales
01 52 (844) 411 32 00
pperez@comimsa.com.mx

Georgina Solís Rodríguez
Instituto Tecnológico de Saltillo
01 52 (844) 4 38 95 00
gsolis@fenix.its.mx

Tomás Eloy Saláis Fierro
ITESM Campus Saltillo
tomas.salais@itesm.mx

Resumen

En este trabajo se analiza un método neuro-difuso para identificar variaciones de control dimensional generadas durante el proceso de ensamble de un producto, esta investigación analiza las ventajas de utilizar técnicas de análisis de componentes principales (ACP) en conjunto con redes neuronales artificiales, así mismo en un segundo caso de estudio se muestra como la lógica difusa puede ser usada para calcular y disminuir el tiempo de ensamble de un producto.

Palabras claves: Lógica Difusa, Análisis de componentes Principales, Redes Neuronales Artificiales, Metodología del Diseño para el Ensamble.

1 Introducción

El proceso de diseño y control de calidad de un producto involucra un complejo grupo de actividades, las cuales se ven afectadas por diversas fuentes de variabilidad, el mal diseño de un producto impacta en su funcionalidad, en ajustes de ensamble y en la percepción del cliente.

Recientemente diversas metodologías basadas en el conocimiento se han propuesto para la

solución de estos problemas buscando mejorar el proceso de diseño y su control de calidad.

La calidad dimensional es una medida de conformancia en la geometría del diseño del producto. Durante el proceso de ensamble de un vehículo, mantener una buena calidad dimensional, es difícil y en algunas ocasiones resulta crítica, debido a las numerosas operaciones

manuales y automatizadas involucradas, así como a gran cantidad de componentes que requiere cada unidad. La variación dimensional es afectada principalmente por este proceso (Jang y Yang, 2001).

Por otro lado, la estimación del tiempo de ensamble de un producto, es difícil de predecir debido a que muchas partes del ensamble no han sido fabricadas, el estudio de tiempos y movimientos ha sido ampliamente usado en la medición del tiempo de fabricación de un producto. Boothroyd y Dewhurst (Boothroyd, Dewhurst, 2001) han desarrollado la metodología de diseño para el ensamble basada en tablas, sin embargo este no se ajusta a todas las situaciones de ensamble en las industrias durante el desarrollo del producto, de ahí que se ha estado investigando el uso de la lógica difusa como un medio

alternativo para el cálculo del tiempo de ensamble de productos nuevos.

Análisis de componentes principales (ACP)

Es un método ampliamente utilizado en estadística para el análisis de datos, se ocupa de explicar la estructura de varianza-covarianza de un conjunto de variables por medio de una combinación lineal de dichas variables. Sus objetivos principales son reducción e interpretación de datos (Jonson,2000).

El objetivo de este método es el de determinar un conjunto de m vectores ortogonales en el espacio de los datos del espacio p -dimensional original (generalmente $p > m$), sobre el subespacio m -dimensional generado por estos vectores, se forman agrupamientos (clusters) que son más viables a ser clasificados mediante la proyección en una dirección de gran varianza. Los componentes principales son combinaciones lineales particulares de p variables aleatorias

x_1, x_2, \dots, x_p . Geométricamente, estas combinaciones representan la selección de un nuevo sistema de coordenadas obtenido mediante la rotación del sistema original con los ejes ordenados y_1, y_2, \dots, y_n . (Figura 1).

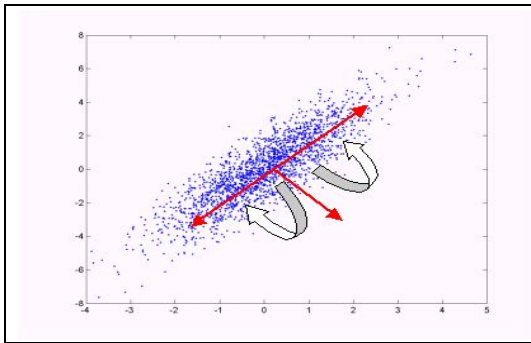


Figura 1 Dirección de máxima varianza y rotación ortogonal.

Los nuevos ejes representan las direcciones con máxima variabilidad y proveen una descripción más simple de la estructura de covarianza.

Supongamos que $x = [x_1, x_2, \dots, x_n]$ es una variable estocástica p -dimensional con media μ y matriz de covarianza Σ . El problema consiste en determinar un nuevo conjunto de variables

$[y_1, y_2, \dots, y_p]$ que no estén relacionadas y

cuya varianza decrece de la primera a la última. Cada una de estas variables y_j se toma como una combinación lineal de las variables x_i de tal forma que:

$$y_j = a_{1,j}x_1 + a_{2,j}x_2 + \dots + a_{p,j}x_p$$

$$y_j = a_j^t x$$

siendo $a_j^t = [a_{1,j} a_{2,j} \dots a_{p,j}]$ con la condición

de que $\|a_j\|_2 = 1$; esto es, $a_j^t a_j = 1$, lo cual asegura que la transformación global sea ortogonal.

El primer componente principal y_1 se determina seleccionando a_1 de tal forma que maximice la

varianza de $y_1 = a_1^t x$ sujeto a la restricción de

que $a_1^t a_1 = 1$. (Jonson,2000).

El segundo componente principal y_2 se determina seleccionando a_2 de tal forma que y_2 tenga la mayor varianza pero que no esté correlacionada con y_1 . En forma similar se puede proceder para y_3, y_4, \dots, y_p con varianza decreciente y que no estén correlacionados. Para determinar y_i se selecciona la varianza de y_i como la función objetivo a maximizar, con respecto a a_i , con la restricción de

que $a_i^t a_i = 1$. Por consiguiente:

$$Var(y_i) = a_i^t \Sigma a_i$$

El problema para determinar la solución óptima de y_i es:

$$\max a_i^t \Sigma a_i \quad \text{s.a.} \quad a_i^t a_i = 1$$

La solución no trivial de $2(\Sigma - \lambda I)a_i = 0$ es el eigenvalor λ_i y el eigenvector a_i de Σ . Pero como Σ es positiva semidefinida, ésta tiene p valores característicos $\lambda_1, \lambda_2, \dots, \lambda_p \geq 0$. Considerando que los eigenvalores son distintos y que $\lambda_1 > \lambda_2 > \dots > \lambda_p \geq 0$. Al maximizar la varianza de y_i se selecciona el mayor valor característico λ_i de Σ ; es decir, el componente principal de a_i es el eigenvector asociado al mayor valor característico λ_i .

Continuando con el mismo procedimiento se encuentra que el j -ésimo mayor eigenvalor λ_j .

Denotando por A la matriz de eigenvectores:

$$A = [a_1, a_2, \dots, a_p]$$

y a y por el vector de componentes principales entonces $y = A^t x$. La matriz de covarianza de y se denota por Λ y

$$Var(y) = \Lambda, \text{ por tanto } \Lambda = A^t \Sigma A, \text{ como } A$$

es una matriz ortonormal, $\Sigma = A\Lambda A'$ por lo tanto, las varianzas de los diferentes componentes se pueden interpretar como los valores característicos de Λ , la suma de varianzas esta dada por ecuación 1.

$$\sum_{i=1}^p Var(y_i) = \sum_{i=1}^p \lambda_i = traza(\Lambda) \quad (1)$$

note que la suma de las varianzas de las variables originales y la suma de las varianzas de los componentes principales son las mismas.

III. Redes neuronales para la extracción de los componentes principales.

Una red neuronal esta basada en la estructura del sistema nervioso humano, es un sistema masivo de unidades simples de procesamiento de información, interconectadas de una manera apropiada. (Ham, Kostanic, 2001)

La información se procesa en elementos simples llamados neuronas; las señales se transmiten a través de conexiones; cada conexión tiene asociado un peso que multiplica la señal transmitida; cada neurona transforma la señal recibida mediante una función de activación para determinar la señal de salida; el aprendizaje se realiza mediante el ajuste de pesos que ponderan las conexiones entre las neuronas que componen la red (figura 2); el algoritmo de aprendizaje es el método por el que se obtienen los ajustes óptimos evitando tener que supervisar todo el proceso.




Figura 2. Estructura de una neurona artificial

Para procesar la información, las neuronas se organizan en capas (entrada, oculta(s), salida); la forma en que las neuronas están conectadas determina la estructura de la red. Una red neuronal con aprendizaje sin supervisión puede establecer la similitud entre un patrón de entrada y

los patrones vistos anteriormente, y aprender gradualmente a identificar patrones típicos (similares); puede construir un conjunto de ejes para medir similitudes respecto a patrones previos (ACP); puede formar categorías sobre la base de correlaciones de los patrones de entrada y decir a que categoría pertenece un patrón de entrada dado o dar como salida un prototipo apropiado (Ham, Kostanic, 2001)

Algoritmo de aprendizaje Hebbiano para el primer componente principal normalizado (Regla de Oja).

Para la estimación del primer componente principal \hat{y}_1 y su eigenvalor asociado \hat{w}_1 de la matriz de correlación Σ , Oja (Ham, Kostanic, 2001) propuso una unidad de procesamiento simple $\hat{y}_1 = \hat{w}_1'x$, utilizando un algoritmo de aprendizaje (corrección a los pesos \hat{w}_1) que determina el vector \hat{w}_1 con las siguientes propiedades:

- El vector de pesos w_1 tiene longitud 1, es decir; $\|w_1\|_2^2 = w_1^T w_1 = 1$.
- El vector de pesos w_1 es un eigenvector de la matriz de covarianza
- w_1 maximiza la varianza de la salida $y_1 = w_1^T x$.

La regla de aprendizaje llamada regla Hebbiana o regla de Oja, se puede establecer como:

$$w_j(k+1) = w_j(k) + \mu(k)[y(k)x_j(k) - y^2(k)w_j(k)]$$

$$j = 1, 2, \dots, n$$

donde $\mu(k) \ll 1$.

a). Algoritmo Hebbiano Generalizado.

Sanger (Sanger, 1999) propuso una regla de aprendizaje capaz de extraer los primeros m eigenvectores principales (figura 3) de la matriz

$$w_{ij}(k+1) = w_{ij}(k) + \mu(k)y_i(k) \left[x_j(k) - \sum_{h=1}^i w_{hj}(k)y_h(k) \right]$$

de covarianza, esta regla fue llamada algoritmo Hebbiano generalizado (GHA).

donde $i=1,2,\dots,n$ y $j=1,2,\dots,n$




Figura 3 Extracción de m componentes principales.

En el desarrollo de este trabajo utilizamos el algoritmo hebbiano generalizado para encontrar sus vectores e igenvalores para analizar como es su comportamiento a la presencia de puntos atípicos.

IV Lógica Difusa

El concepto de Lógica Difusa fue concebido por Lofti Zadeh un profesor de la Universidad de California en Berkley, quien no estaba de acuerdo con la sola existencia de los conjuntos clásicos (crisp sets) (Yen, Reza, 1999).

La lógica difusa permite trabajar información con alto grado de imprecisión a diferencia de la lógica convencional que trabaja con información bien definida y precisa, esta es una metodología que obtiene una conclusión a partir de información de entrada vaga, ambigua, imprecisa, con ruido o incompleta, en general la lógica difusa imita cómo un persona toma decisiones basada en información con las características mencionadas (Yen y Reza, 1999).

V. Caso de estudio No. 1

La aplicación de la técnica se llevo a cabo en el panel trasero de una camioneta (figura 4); En la cual se consideraron siete variables o puntos críticos de control de ensamble , estos puntos fueron inspeccionados mediante un total de 84 mediciones con el fin de encontrar cual es el mas problemático con el fin de determinar cual seria su posible fuente de variación. Se realizaron pruebas de normalidad para las variables seleccionadas; estas fueron satisfactorias, se analizaron gráficos de control para cada variable, algunos de estos mostraban que algunos puntos se encontraban fuera de especificaciones.

Se calculo la matriz de correlación para las variables utilizadas, obteniendo altas correlaciones entre las variables de estudio, por lo que se procedió a llevar a cabo el ACP enfoque neural por sus ventajas frente al método tradicional.




Figura 4 Panel trasero de la camioneta mostrando los puntos críticos que se analizaron

Eigenvalores:	3.335	1.319	1.058	0.836	0.274
Proporción:	0.477	0.188	0.151	0.120	0.039
Acumulada:	0.477	0.665	0.816	0.936	0.975
Eigenvalores:	0.149	0.025			
Proporción:	0.021	0.004			
Acumulada:	0.996	1.000			

Tabla No. 1 Análisis tradicional de componentes principales.

Variabl e	Mediante estadística			Redes Neuronales		
	PC1	PC2	PC3	PC1	PC2	PC3
20Z_L	0.227	0.351	0.228	0.23 3	-0.36 2	0.220
26Z_L	0.487	-0.303	-0.126	0.48 9	0.295 6	-0.12
77Y_L	0.392	-0.209	-0.526	0.39 1	0.205 2	-0.53
77Z_L	0.484	-0.333	0.049	0.47 9	0.326	0.055

24Z_R	0.164	-0.385	0.776	0.14	0.390	0.781
29Z_R	0.389	0.483	-0.044	0.38	-0.48	-0.05
77Z_R	0.390	0.496	0.219	0.39	-0.50	0.218
			4	6	5	0
			6	9	9	

Tabla No. 2 Tabla comparativa de los tres primeros componentes principales, encontrados mediante estadística convencional y utilizando redes neuronales, así mismo se muestran los eigenvalores encontrados y su correspondiente aportación.

El eigenvalor para un componente principal indica la varianza tomada en cuenta por dicho componente con respecto a las varianzas totales de 7.000.

De esta forma el primer componente principal toma en cuenta $(3.3356/7.000)100\%=47.7\%$ de la variación total, El segundo 0.188%, el tercero 0.151%, el cuarto 0.120%, el quinto 0.039%, el sexto y séptimo 0.021% y 0.004%, claramente el primer componente es por mucho mas importante que los otros.

El primer componente principal mediante redes neuronales es:

$$y_1 = -0.212x_1 - 0.485x_2 - 0.393x_3 - 0.491x_4 - 0.162x_5 - 0.386x_6 - 0.385x_7$$

por tanto alrededor del 47.7% de la variación en los datos está relacionada con las alturas de las dimensiones en los puntos medidos. Los otros componentes se interpretan de manera similar.

Podemos concluir que el empleo de una red neuronal tiene grandes ventajas sobre los métodos estadísticos tradicionales (tabla 2), no es necesario calcular la matriz de covarianza del conjunto de datos, se pueden encontrar los eigenvectores e igenvalores directamente de los datos, la red puede realizar perfectamente los cálculos no importa si faltan datos o existen puntos atípicos; puede generalizar la información que tiene debido a su tolerancia a fallos.

Se están realizando investigaciones empleando diferentes funciones correctoras de transferencia con el fin de encontrar cual sería la que nos pudiera dar mejores aproximaciones, se inicio empleando la función tangente hiperbólica la cual reduce el nivel de aproximación, pero se continuara experimentando con otras mas para dar

una conclusión de cual sería la mas recomendable para este tipo de problemas.

VI. Caso de estudio No. 2 Calculo del tiempo de ensamble mediante lógica difusa

Con el fin de analizar el potencial de la lógica difusa aplicada al diseño para el ensamble y el como esta metodología puede ser de gran ayuda a la toma de decisiones. Se realizo una experimentación con el fin de calcular el tiempo de ensamble de un producto nuevo que aun no ha sido fabricado.

Basándonos en la información recolectada entre personal experimentado del área de ensamble de una empresa dedicada a la fabricación de componentes se establecieron los parámetros cualitativos que ellos consideran se ven involucrados en el ensamble de un producto y cual sería el rango que pudieran tener. Como ejemplo de los resultados obtenidos, encontramos que los valores para las variables simetría, métodos de ensamble, facilidad de acceso, inserción y tiempo se determinaron asignándoles un rango entre 0 y 1, la variable a la que se le asignará el valor más alto entre cero y uno correspondería a la que tuviera la característica mas critica , puede ser la más pesado, la más difícil acceso o de mas difícil inserción dentro de un ensamble. así como mismo se estableció para la variable de salida tiempo los siguientes rangos, tiempo bajo (10-25) min., normal (15-35) min. y alto de 35 min.



Figura 5 Mostrando los rangos de la variable dimensión y como sería su pertenencia.

Para determinar el tiempo necesario en el ensamble de un producto se proceso la información proporcionada al programa para ver cómo es su comportamiento, en la figura 5 se muestra la variable de entrada *dimensión* con los rangos que fue considerada.

Ejemplo De una regla:

1. Si el peso es =grande y la dimensión es grande el tiempo de ensamble es alto.
2. Si el peso es=ligerito y la dimensión es pequeña y la simetría =totalmente , el tiempo de ensamble es bajo
3. si el peso = ligero y la dimensión =grande y el método de manejo es con una mano el tiempo de ensamble es mediano.

Con esta información se procedió a realizar un análisis en conjunto de todas las variables en donde de una manera automática mediante la lógica difusa, podemos calcular el tiempo de ensamble de una manera rápida y precisa, sin estar sujetos a consultar información de tablas como se realiza con la metodología de ensamble propuesta por (Boothroy, Dewhurst, 2001). Resultando esta metodología basada en lógica difusa en un buen método complementario para el cálculo del tiempo de ensamble.

VII. Conclusiones

1. El objetivo del ACP mediante redes es determinar un conjunto de m vectores ortogonales en el espacio de los datos que contengan la mayor información posible de la varianza de los mismos, sobre los cuales se proyectarán los datos del espacio p -dimensional original sobre el subespacio m -dimensional generado por estos vectores.
2. Los componentes principales obtenidos de forma neuronal resultan ser más significativos (explican mejor la variabilidad del proceso y son tolerantes debido a información faltante o contaminada).
3. Se encontró que aplicando tanto el algoritmo de Oja como el algoritmo generalizado Hebbiano presentan cierta inestabilidad a la presencia de puntos atípicos, que es conveniente trabajar sobre técnicas para complementarlo (utilizar alguna función de transferencia).
4. Se ha experimentado el beneficio que representa el uso de la lógica difusa como apoyo en el cálculo de tiempos ensamble de un producto, pudiendo esta técnica complementar a la metodología de diseño para el ensamble (DFA).

VIII Trabajo futuro

Los resultados obtenidos hasta el momento demuestran que la utilización del ACP permite analizar el comportamiento de las variables en el control de la calidad dimensional, se continua trabajando en la investigación para integrar lógica difusa a los resultados de la red basada en componentes principales y que el sistema inteligente a desarrollar nos indique las acciones a realizar de acuerdo a los resultados de los componentes principales encontrados.

Con respecto a la aplicación de la lógica difusa para el cálculo del tiempo de ensamble, se esta trabajando en el desarrollo de una red basada en componentes principales para la optimización del tiempo de ensamble y parámetros de diseño del producto, así mismo se esta experimentando con el uso de funciones de transferencia y determinar la mas adecuada.

IX. Referencias

Boothroy Geoffrey, Dewhurst Winston. (2001) Product Design for Manufacturing and Assembly New York: Marcel Dekker.

Guanghsu A Chang (2003) Fuzzy Logic to DFA , National Taipei University of Technology 8th Annual International Conference on Industrial Engineering, Las Vegas Nevada, November 2003 No. SS087.

Ham Fredrick y Kostanic Ivica, (2001) Principles of Neurocomputing for Science and Engineering; Mc Graw Hill.

Jin and B. Sendhoff. (2001) Knowledge incorporation into neural networks from fuzzy rules. Neural Processing Letters, vol. 10, 231-242, 2001.

Johnson(2000) and Wichirn; Applied multivariate statistical analysis; ed. Prentice Hall; fourth edition.

Khi-Young Jang, Kai Yang; (2001) Journal Manufacturing Systems, Improving principal component analysis (PCA) in automotive body assembly using ANN; vol. 20; pp. 188-197.

Sanger T.D. (1989) "Optimal Unsupervised Learning in a Single-Layer Linear Feedwork Neural Network, "Neural Networks, vol. 2, pp.459-73.

Yen John, Reza Langari (1999) Fuzzy Logic
Intelligence, Control and Information
PrenticeHall.