

Planificación de la Demanda en la Gestión de Cadena de Suministro con Redes Neuronales y Lógica Difusa¹

Nicolay A. Mena O'meara¹, Francisco-Cruz Lario Esteban², Eduardo Vicens Salort³

¹ Centro de Investigación Gestión e Ingeniería de Producción (CIGIP). UPV. Valencia. nimeom@doctor.upv.es

³ Centro de Investigación Gestión e Ingeniería de Producción (CIGIP). UPV. Valencia. fclario@omp.upv.es

² Centro de Investigación Gestión e Ingeniería de Producción (CIGIP). UPV. Valencia. evicens@omp.upv.es

Resumen

Con este documento se pretende dar a conocer una aproximación novedosa para mejorar la previsión de la demanda en la Gestión de la Cadena de Suministro, en particular, la diferencia entre demanda prevista en un determinado horizonte y demanda real, cuya reducción es clave para evitar generación de inventarios en exceso y/o alcanzar los niveles de servicio a los clientes que son determinantes del éxito de las empresas en el entorno actual del mercado. La metodología utilizada se basa en un modelo de redes neuronales y Lógica difusa, modelo que últimamente ha tenido gran acogida por muchos investigadores interesados en la previsión de la demanda de la GCS.

Palabras clave: Previsión, Demanda, Lógica difusa, Redes neuronales

1. Introducción

En el entorno actual del mercado, la volatilidad de la demanda, la cada vez menor fidelidad de los clientes, los ciclos de producto cada vez más cortos y la dura competencia global, son elementos cuya presencia es incuestionable. Las empresas necesitan, cada vez más, información que les permita tomar las decisiones correctas, en tiempo real, que aseguren la satisfacción de sus clientes como su primera prioridad, a la vez que se mantienen competitivas y protegen sus márgenes comerciales. Errores en las previsiones de la demanda, cuando es en ésta en la que se basa la compra de materiales y la planificación de la capacidad de producción, generan no solo inventarios en exceso, si no también clientes insatisfechos a los que no podemos servir. Los fabricantes están cada vez más utilizando técnicas más sofisticadas de planificación, con las que desarrollan sus planes de producción en respuestas a cambios súbitos de la demanda. Los datos que se manejan no solo vienen de las propias organizaciones, sino que muchas veces vienen de proveedores, agentes distribuidores e incluso de los propios clientes.

Los grandes proveedores de soluciones de ERP ya tienen módulos de fácil integración en el sistema, con las interfaces adecuadas para recibir la información que puede llegar de fuentes

¹ * Este trabajo se ha realizado en el ámbito del proyecto del MINISTERIO DE EDUCACIÓN Y CIENCIA “De la Planificación a la Ejecución en la Cadena (Red) de Suministro: Dos visiones diferentes y sus herramientas (DPI2004-06916-C02-01)”.

externas, pero, en general, la información que manejan son datos estadísticos del comportamiento del negocio en el pasado, así como elementos que previsiblemente modificarán la demanda y cuya influencia se halla a través de determinados algoritmos o reglas de decisión. Estos métodos estadísticos convencionales usan en general determinados parámetros o datos asociados a periodos de tiempo cuya relación con la Previsión de Demanda es complicadísima; la realidad es que, muchos de los que toman decisiones en el campo de la previsión de demanda, lo hacen basándose en su instinto y experiencia, experiencia que utilizan para valorar el impacto de campañas promocionales, de introducción de nuevos productos, etc. Además, la realidad también nos dice que la mayor parte de las veces, la demanda se establece con un requisito primordial, el que debe soportar el plan financiero o plan de ventas, con lo cual, la mayor parte de las veces, el proceso de planificación de la demanda está fuertemente condicionado por elementos que, en principio, tienen que ver con el mercado y los clientes.

El pronóstico de la demanda desempeña un papel muy importante en la Gestión de Cadena de Suministro. Obtener los pronósticos de demanda en la Cadena de Suministro puede ayudar a los expertos que toman las decisiones de cálculos de costos de producción y de materia prima, así como determinar los precios de ventas. Esto tiene como resultado niveles más bajos de inventario y lograr el JIT. La mayoría de métodos de previsión de demanda en la Cadena de Suministro utilizan datos de series temporales para determinar el pronóstico. Sin embargo, la relación entre los factores o datos pasados de serie temporales (variables independientes) y las ventas (variable dependiente) es bastante complicada, así que obteniendo los resultados de los enfoques dichos es bastante difícil. Las numerosas investigaciones tratan este problema y generalmente emplean métodos estadísticos, tales como los métodos autoregresivos de medias móviles. Sin embargo, el pronóstico de la demanda es muy incierto debido a la influencia de ambientes internos y externos. Recientemente, las redes neuronales artificiales (ANNs) se están aplicando en el pronóstico de la demanda por su funcionamiento prometedor en áreas de reconocimiento. Sin embargo, mejorar estos pronósticos sigue siendo necesario para circunstancias únicas. Lo que se pretende es usar una Red Neuronal Difusa (FNN), que puede eliminar los pesos poco importantes a partir de algoritmos genéticos, para aprender reglas difusas IF-THEN obtenidas por expertos en el tema. El resultado de las FNN se profundiza con datos de series temporales a través de ANN.

2. Estado del Arte

El pronóstico es una de las actividades más importantes para mejorar la productividad y mejorar la calidad en toda una función organizacional porque la mayor parte de los resultados de pronóstico son muy influyentes en la toma de decisiones de gestores y en el desarrollo de una compañía. En muchos casos, los sistemas de pronósticos son desarrollados para servir como instrumentos de diagnóstico para identificar las deformaciones potenciales en actividades organizacionales (Fildes y Hastings, 1995).

Por ejemplo, la predicción de los defectos de un producto durante el proceso industrial, son el principio de actividades de mejora de calidad, y siendo estos resultados de pronóstico utilizados para controlar correctamente el futuro de los procesos de producción de los productos de más alta-calidad (Makridakis y Faucheux, 1996). Estos autores se enfocan en el desarrollo de un *sistema computarizado de pronóstico causal* para pronosticar eficientemente varios **índices de rendimiento** implicados en la Cadena de Suministro, lo cuales abarcan procesos enteros de inputs y outputs de logística en una compañía, desplazándose desde el suministro de material hasta la entrega a los consumidores finales.

Según (Bongju Jeong, Ho-Sang Jung, Nam-Kyu Park, 2002) la Cadena de suministro consta de 3 etapas: Proveedor, Producción y Distribución. Estas etapas también implican tres entidades de negocio como se muestra en la Fig. 1: Suministradores, Fabricantes y Clientes los cuales inician y ejercen esfuerzos en cada correspondiente etapa. Muchos investigadores consideran a los distribuidores y a los detallistas como entidades claves del negocio (Beamon, 1998).

Aunque muchas actividades y diversas funciones se incluyen en cada etapa, este estudio pretende enfocarse a las actividades de pronósticos. Reconocer la importancia de una actividad de pronóstico determinará cuán efectiva es la Cadena de Suministro bajo un ambiente externo e interno de Incertidumbre. Las actividades de pronóstico en una Cadena de Suministro son diferentes una de otra según sus variables de pronóstico y sus etapas implicadas, como es mostrado en el Fig. 1.

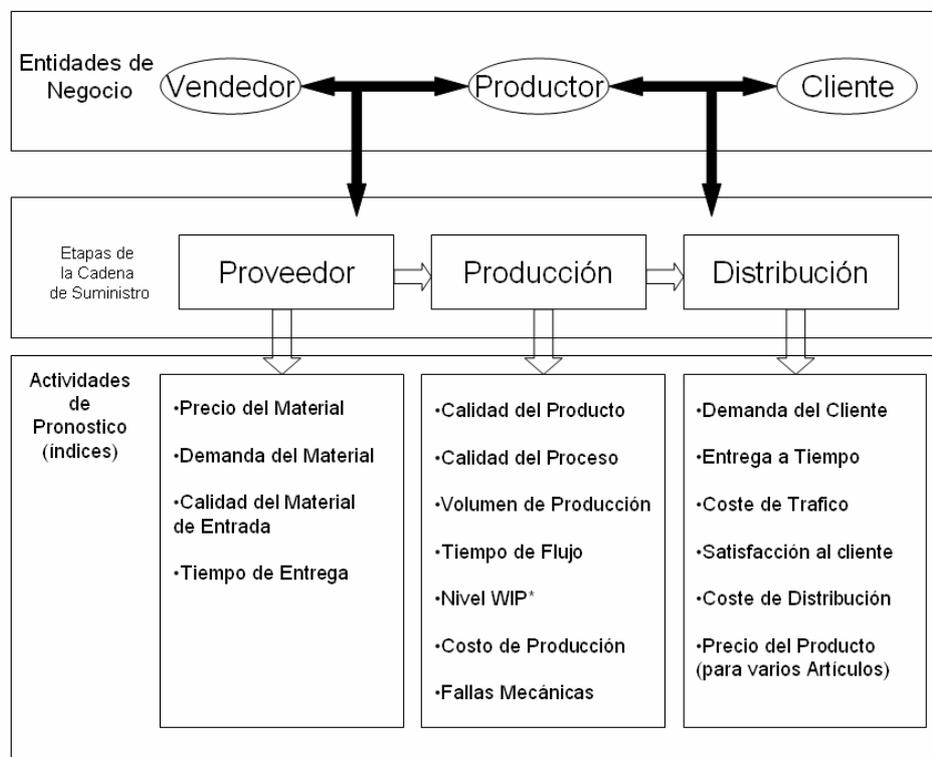


Figura 1, Actividades de Pronóstico en la Cadena de Suministro

Numerosas investigaciones para determinar el Pronóstico de la Demanda tratan este problema y generalmente emplean métodos estadísticos, tales como los Métodos Auto Regresivos y de Medias Móviles (ARMA). Sin embargo, el Pronóstico de la Demanda es muy incierto debido a la influencia de ambientes internos y externos. Recientemente, las Redes Neuronales Artificiales (ANNs) se están aplicando en el Pronóstico de la Demanda por su funcionamiento prometedor en áreas de reconocimiento. Sin embargo, mejorar estos pronósticos sigue siendo necesario para circunstancias únicas. Así, en este estudio lo que se pretende es dar a conocer el funcionamiento de una Red Neuronal Difusa (FNN), que pueda eliminar los pesos de poca importancia, para luego aprender reglas IF-THEN difusas obtenidas de expertos de cada Etapa (Proveedor, Producción y Distribución) de la Cadena de Suministro respecto a la Previsión de la Demanda. El resultado de las FNN se profundiza con los datos de series

temporales a través de una ANN. Según varios estudios (R.J. Kuo, P. Wu y C.P. Wang, 2002) los resultados obtenidos con las FNN con eliminación de pesos son mejores que los obtenidos con las FNN, superando los métodos estadísticos y a las ANN solamente en exactitud.

ANN (Redes Neuronales Artificiales)

Los métodos de pronósticos convencionales según (Meyer; Chase y Florance; 1993), la mayoría de ellos utilizan diferentes factores o datos de series de temporales para determinar el pronóstico. Sin embargo, la relación entre los factores o los datos pasados de series temporales (variables independientes) y la Previsión de la Demanda (la variable dependiente) es difícil de entender. Obtener resultados prometedores para estos enfoques es bastante difícil. Por lo tanto, diferentes personas toman decisiones y prefieren utilizar su propia intuición, en vez de enfoques basados en modelos de serie temporales o modelos de regresión. Sin embargo, un modelo-libre como lo es el de ANN, que se aplica en el área de pronósticos y debido a su recientemente desempeño es adecuado para el reconocimiento de patrones en control (Automática).

Las ANN son sistemas derivados por modelos de neurofisiología. En general, consisten en una colección de operaciones no lineales y sencillas cuyas entradas y salidas interaccionan para formar una red. En muchos estudios se han usado las ANN para pronosticar las series temporales, aunque sus conclusiones sean a menudo contradictorias. Algunos estudios como los de, (Weigen et al., 1991), dicen que las ANN son métodos de fiar, mientras otros estudios como los de (Tang et al., 1991) contradicen lo de Weigend. (Weigen et al., 1991) introdujo la eliminación de pesos a través del algoritmo *backpropagation*² aplicado al estudio de manchas solares.

Adicionalmente, las ANN se han comparado con los métodos de *box-Jenkins* en trabajos como el de tráfico de pasajeros en una aerolínea internacional, ventas domésticas de coches y ventas de coches en los EEUU (Tang et al., 1991). Se concluyó que los modelos de *Box-jenkins* superaron a los modelos de ANN en el pronóstico a corto plazo, aunque las ANN superaron al modelo de *Box-jenkins* en el pronóstico a largo plazo. (Chakraborty et al., 1992) presentó un enfoque de las ANN analizando las series temporales multivariantes, usando pronósticos en los precios de harina de tres ciudades de EEUU, demostrando que el mejor desempeño lo presentaron las ANN. Además, (Lachtermacher y Fuller., 1995) presento un modelo calibrado de ANN, que usa el modelo *Box-jenkins* para identificar datos de "componentes de demora". Este modelo empleó también un método heurístico para sugerir el número de unidades necesarias para estructurar el modelo.

FNN (Redes Neuronales Difusas)

Las ANN y los modelos difusos se han utilizado en muchas áreas de aplicación (Zadeh, 1973; Lippmann, 1987 y Lee, 1990), mostrando sus ventajas y desventajas. Por lo tanto, al combinar estos dos modelos ha tenido gran éxito.

²**Algoritmo Backpropagation** (es un algoritmo de una red neuronal retroalimentada), la cual se nos presenta como un algoritmo de aprendizaje supervisado que busca predecir la variable necesitada; se necesita conocer los valores de salida esperados (los cuales son obtenidos por medio de recopilación datos de un promedio histórico), y los asocia con las entradas, para tener un reconocimiento o clasificación de patrones actualizando pesos y ganancias.

Últimamente hay dos modelos que son de mucho interés: (1) las ANN y (2) la lógica difusa. La lógica difusa se basa en el conocimiento de expertos. Sin embargo, no es muy objetiva. Además, adquirir conocimientos robustos y encontrar expertos disponibles en el tema es difícil. Las redes neuronales y la lógica difusa son consistentes universales, estas pueden aproximar cualquier función no lineal, esto a partir de su funcionamiento interno con neuronas ocultas suficientes o con reglas difusas que estén disponibles. Recientemente los resultados dicen que la fusión de las dos tecnologías parece ser muy eficaz para modelar una clase extensamente de sistemas complejos no lineales donde no se tenga información completa de algún modelo. Hoy en día se trabaja, con algoritmos de ANN que aprenden por si mismos para aumentar el desempeño de sistemas difusos y se ha demostrado que son innovadores. Además, las reglas difusas IF-THEN nacieron y fueron ajustadas aprendiendo de métodos que usan los datos numéricos. (Takagi y Hayashi, 1991) introdujeron una ANN hacia a delante con lógica difusa. (Jang, 1991, 1992; y Jang y Sun, 1993) propusieron un método que transforma el sistema difuso en una red capaz de adaptarse a un medio equivalente y funcional, empleando un algoritmo Error-Backpropagation (EBP) para actualizar los parámetros de premisas e identificar los parámetros de consecuencia. Mientras tanto, (Shibata; Wang y Fukuda, 1992) presentaron métodos semejantes. (Lin y Lee, 1991) propusieron un Sistema difuso, basado en un Control de Lógica con una Red Neuronal (NN-FLCS). Ellos introdujeron un bajo nivel de aprendizaje a las redes neurales y a la lógica difusa para tener una arquitectura de conexiones normales. Además, (Kuo, R. J., & Xue, K. C., 1999) introdujeron una ANN hacia a delante (se refiere a un aprendizaje hacia a delante) con lógica difusa representada por el modelo de Takagi-Sugeno³.

3. Aspectos Claves para la Metodología

Primero que todo se discute con el gestor de cada Etapa (Proveedor, Producción y Distribución) de la Cadena de Suministro para poder seleccionar la actividad de pronóstico (índices) de la Etapa a pronosticar, luego se examinan las actividades de pronóstico seleccionadas y se discute con los expertos de cada Etapa de la Cadena de Suministro para determinar los factores importantes que afectan la Previsión de la Demanda. Luego se recolectan todos los factores que afectan cada actividad de pronóstico seleccionada y ya teniendo éstas se usan las FNN para establecer reglas IF-THEN. Esto para pronosticar los efectos de la Previsión de la Demanda. Ya teniendo los efectos de la Previsión de la Demanda se integran los datos diarios de las series temporales de la Previsión de Demanda de la Etapa a pronosticar con los efectos de la Previsión de la Demanda de la Etapa a pronosticar.

Para manejar el efecto de la Previsión de la Demanda se necesita un enfoque más robusto y por esto se usan Redes Neuronales Difusas (FNN) y Redes Neuronales Artificiales (ANN).

Para pronosticar con un sistema inteligente se necesita según (Kuo, R. J., P. Wu, C.P. Wang, 2002):

- (1) Recolección de datos,
- (2) un modelo especial Redes Neuronales Difusas como pauta, e
- (3) integración para la toma de la decisión con una Red Neuronal Artificial.

³ Modelos del tipo Takagi-Sugeno: Son las funciones que definen los parámetros del consecuente. Para la premisa, los parámetros son los que definen los conjuntos difusos que particionan el espacio de entrada.

La Figura 2 muestra la arquitectura propuesta del sistema. El sistema determina primero los factores cualitativos⁴ que afectan la Previsión de la Demanda. Después estos factores se integran con datos de series temporales (factores cuantitativos⁵) por una red neuronal hacia adelante con un algoritmo de error backpropagation (EBP).

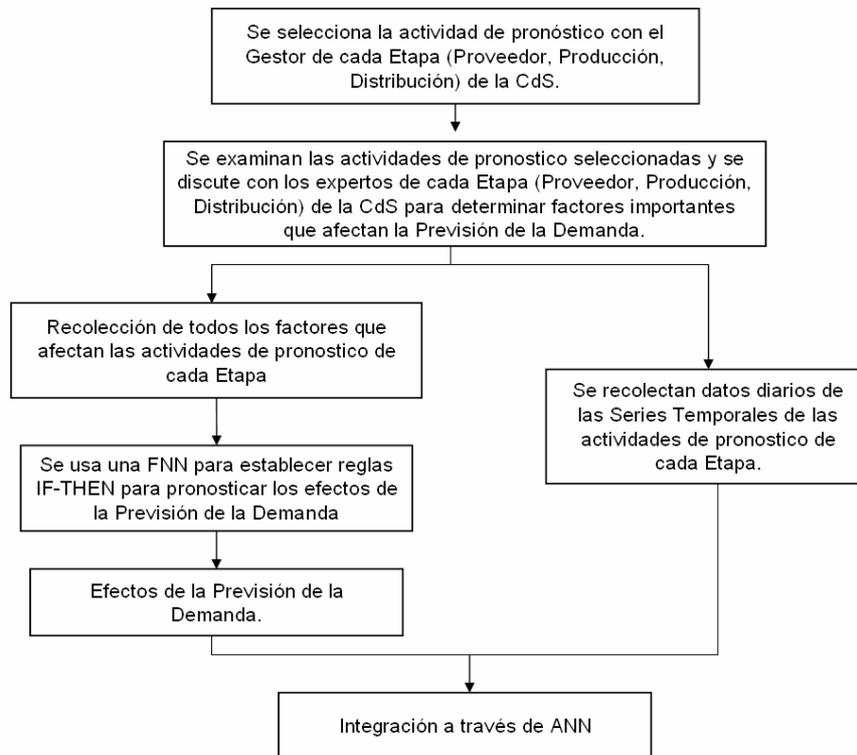


Figura 2, Arquitectura de la Metodología.

Recolección de Datos

Esto requiere dos clases de datos diferentes, que incluyen datos cuantitativos y cualitativos. En la Etapa a pronosticar de la Cadena de Suministro se deben proporcionar datos diarios de las actividades de pronóstico necesitadas, mientras que el efecto de previsión de demanda de la Etapa a pronosticar puede ser aplicado por reglas IF-THEN. En este estudio se pretende usar decisiones difusas para obtener reglas difusas IF-THEM de los expertos del dominio.

Para dirigir efectivamente una circunstancia de previsión de demanda por medio de FNN; la arquitectura de las FNN se basa en lógica difusa que posee una condición previa y una

⁴Las técnicas cualitativas se usan cuando los datos son escasos, por ejemplo cuando se introduce un producto nuevo al mercado. Estas técnicas usan el criterio de la persona y ciertas relaciones para transformar información cualitativa en estimados cuantitativos.

⁵Las técnicas cuantitativas son Análisis de Series de Tiempo. El análisis consiste en encontrar el patrón del pasado y proyectarlo al futuro.

consecuencia; las variables de condición previa representan los factores efectivos mientras la demanda representa variables de consecuencia.

Para poder aplicar esta metodología se debe buscar el método que sea más conveniente para obtener los datos y las reglas IF-THEM. Después de este procedimiento, los datos se pueden aplicar para entrenar la FNN propuesta. La estructura estudiada de FNN es similar a la de (Ishibuchi et al., 1995). La diferencia principal es que la red que se pretende emplear es la de distribución de campana asimétrica en vez de distribución triangular con pesos borrosos. Además, la red puede eliminar los pesos poco importantes durante la instrucción.

3. Conclusiones

Se pretende desarrollar un sistema de pronóstico de demanda basado en redes neuronales y lógica difusa para resolver los problemas de previsión de demanda en la Cadena de Suministro. Se quiere proporcionar mediante la integración de las redes neuronales y las redes neuronales difusas pronósticos más seguros. Y mediante esta metodología lo que se pretende es que el sistema aprenda de datos históricos para que cada vez mejore la respuesta deseada.

Se quiere mostrar, que actualmente para la previsión de la demanda es muy útil usar redes neuronales difusas y redes neuronales artificiales; donde lo que se pretende es hacer que los investigadores se familiaricen mas con este tipo búsqueda para tener una optima solución a la hora de hacer una previsión de demanda.

Referencias Bibliográficas

Beamon, B.M., 1998. *Supply chain design and analysis: models and methods*. *International Journal of Production Economics* 55, 281–294.

Bongju Jeong, Ho-Sang Jung, Nam-Kyu Park, (2002). *A computerized causal forecasting system using genetic algorithms in supply chain management*; *The Journal of Systems and Software* 60 (2002) 223–237

Chase, C. W. (1993). *Ways to improve sales forecasts*. *Journal of Business Forecasting*, 12(3), 15–17.

Chakraborty, K., Mehrotra, K., & Mohan, C. K. (1992). *Forecasting the behavior of multivariate time series using neural networks*. *Neural Networks*, 5(6), 961–970.

Faucheux, C., 1996. *Forecasting: its role and value for planning and strategy*. *International Journal of Forecasting* 12, 539–546.

Fildes, R., Hastings, R., 1995. *The organization and improvement of market forecasting*. *IEEE Engineering Management Review* 23, 33–44.

Florance, M. M., & Sawicz, M. S. (1993). *Positioning sales forecasting for better results*. *Journal of Business Forecasting*, 12(4), 27–28.

- Fukuda, T., & Shibata, T. (1992). *Hierarchical intelligent control for robotic motion by using fuzzy, artificial intelligence, and neural network*. Proceedings of IJCNN'92 (pp. I-269–I-274).
- Ilan Alon, Min Qi, Robert J. Sadowski (2001). *Forecasting aggregate retail sales: a comparison of artificial neural networks and traditional methods*
- Ishibuchi, H., Kwon, K., & Tanaka, H. (1995). *A learning algorithm of fuzzy neural networks with triangular fuzzy weights*. Fuzzy Sets and Systems, 71, 277–293.
- Jang, J. -S. R. (1991). *Fuzzy modeling using generalized neural networks and kalman filter algorithm*. Proceedings of Ninth National Conference on Artificial Intelligence (pp. 762–767).
- Jang, J. -S. R. (1992). *Fuzzy controller design without domain expert*. IEEE International Conference on Fuzzy Systems (pp. 289–296).
- Jang, J.-S. R., & Sun, C.-T. (1993). *Functional equivalence between radial basic function networks and fuzzy inference systems*. IEEE Transactions on Neural Networks, 4(1), 156–159.
- Kuo, R. J., K.C., Xue, (1997). *Fuzzy Neuronal Networks with applications to sales forecasting*
- Kuo, R. J., & Xue, K. C. (1999). *Fuzzy neural network with application to sales forecasting*. Fuzzy Sets and Systems, 108(2), 123–143.
- Kuo, R. J. (1999). *A sales forecasting system based on fuzzy neuronal network with initial weights generated by genetic algorithm*.
- Kuo, R. J., P. Wu, C.P. Wang (2002). *An intelligent sales forecasting system through integration of artificial neural networks and fuzzy neural networks with fuzzy weight elimination*.
- Lachtermacher, G., & Fuller, J. D. (1995). *Backpropagation in time-series forecasting*. Journal of Forecasting, 14, 381–393.
- Lee, 1990. C.C. Lee , *Fuzzy logic in control systems: Fuzzy logic controller—Parts I and II*. *IEEE Transactions on Systems, Man, and Cybernetics* **SMC-20** 2 (1990), pp. 404–435
- Lin, C. T., & Lee, C. S. G. (1991). *Neural-network-based fuzzy logic control and decision system*. IEEE Transactions on Computer, C-40(12), 1320–1336.
- Lippmann, 1987. R.P. Lippmann , *An introduction to computing with neural nets*. *IEEE ASSP Magazine* (1987), pp. 4–22.
- Makridakis, S., 1996. *Forecasting: its role and value for planning and strategy*. International Journal of Forecasting 12, 513–537.

Meyer, G. G. (1993). *Marketing research and sales forecasting at schlegel corporation*. *Journal of Business Forecasting*, 12(2), 22–23.

Takagi and Hayashi, 1991.T. Takagi and I. Hayashi , *NN-driven fuzzy reasoning*. *International Journal of Approximate Reasoning* 5 (1991), pp. 191–212.

Tang, Z., Almeida, C., & Fishwick, P. A. (1991). *Times series forecasting using neural networks vs. Box–Jenkins methodology*. *Simulations*, Simulations Councils, 303–310.

Wang, L.-X., & Mendel, J. M. (1992). *Back-propagation fuzzy system as nonlinear dynamic system identifiers*. *IEEE International Conference on Fuzzy Systems* (pp. 1409–1418).

Weigen, A. S., Rumelhart, D. E., & Huberman, B. A. (1991). *Generalization by weight-elimination with application to forecasting*. *Advances in Neural Information Processing Systems*, 3, 875–882

Zadeh, L. A. (1973). *Outline of a new approach to the analysis of complex systems and decision processes*. *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-3(1), 28–44.