

DISEÑO DE UN SISTEMA DE SURTIMIENTO DE MATERIAL A LÍNEAS DE PRODUCCIÓN A TRAVÉS DE UNA RED NEURONAL ARTIFICIAL

DESIGN OF A MATERIAL SUPPLY SYSTEM TO LINES THROUGH AN ARTIFICIAL NEURAL NETWORK

Jorge Lazarini Díaz Barriga

Tecnológico Nacional de México en Celaya
Jorge_lazarini1991@hotmail.com

Vicente Figueroa Fernández

Tecnológico Nacional de México en Celaya
vicente.figueroa@itcelaya.edu.mx

José Antonio Vázquez López

Tecnológico Nacional de México en Celaya
antonio.vazquez@itcelaya.edu.mx

José Alfredo Jiménez García

Tecnológico Nacional de México en Celaya
alfredo.jimenez@itcelaya.edu.mx

Resumen

Dentro de las líneas de producción, es común encontrarse con personas encargadas de mandar señales de surtimiento cuando estas son requeridas. Éstos son llamados arañas de agua. Su tarea es de suma importancia debido a que, al dar un seguimiento cercano a cualquier retraso o escasez de material, se evita tener tiempos muertos en líneas. Un área de oportunidad dentro de las empresas radica en el dar respuestas más prontas a las necesidades. Esto se puede lograr implementando sistemas más rápidos y eficientes a la hora de localizar un posible error en los faltantes de artículos en una línea de producción. En el presente trabajo se propone el diseño de un sistema de surtimiento de material a líneas de producción en base a redes neuronales artificiales. El objetivo es dar señales rápidas y confiables de surtimiento a una línea de producción en función de variables establecidas en este trabajo. Estas cualidades pretenden evitar el agotamiento de material por surtimiento tardío.

Palabra(s) Clave: Araña de agua, Manufactura Esbelta, Redes Neuronales Artificiales, Surtimiento.

Abstract

Within the production lines, it is common to find people in charge of sending supply signals when they are required. These people are called water spiders. This task is very important because, by closely monitoring any delay or shortage of material, dead time in lines is avoided. An area of opportunity within companies lies in giving quicker responses to the needs. This can be achieved by implementing faster and more efficient systems when locating a possible error in the missing articles in a production line. The objective is to give a quicker and reliable signs of supply to a production line based on the variables established in this work.

Keywords: Artificial Neural Networks, Lean Manufacture, Supply, Water Spider.

1. Introducción

Un buen surtimiento y monitoreo de materiales en las líneas de producción es un factor muy importante para el éxito dentro de las industrias manufactureras. Evitar problemas relacionados a pérdidas de tiempo es igual a generar más producción y por ende más ganancias. Dentro de una empresa la importancia de una línea de producción eficaz radica en el cumplimiento de objetivos de producción en el tiempo determinado [Chase, 2008].

Los tiempos de entrega son programados para surtir el producto terminado en el tiempo indicado. Sirven también para generar conocimiento del momento preciso en el que se va a dejar de utilizar las estaciones de trabajo para poder fabricar el siguiente lote programado en esa línea.

Teniendo estos objetivos trazados, es de suma importancia dar un seguimiento cercano a cualquier retraso en la escasez o surtimiento inicial de artículos que pueda surgir en la línea de producción [Chase, 2008].

El proceso actualmente es llevado por personal humano. A esta persona encargada de esta actividad se le conoce como araña de agua. La araña de agua opera con información obtenida de la línea de producción como lo es el plan maestro de

producción, el trabajo en proceso, inventario y partes a ser surtidas a la línea de producción específica, en el tiempo, lugar y cantidad exacta para que no se generen desperdicios [Nomura, 2006].

Se requiere de dar respuestas más prontas a las necesidades, implementando sistemas más rápidos y eficientes a la hora de localizar un posible error en los faltantes de artículos en una línea de producción. La propuesta consiste en el diseño de un programa en base a redes neuronales artificiales que tome las decisiones de la araña de agua.

Las redes neuronales artificiales es un tipo de programación la cual trabaja sin algoritmo de procesamiento de información. A diferencia de la programación convencional, las redes neuronales artificiales sustituyen este algoritmo de programación por uno de entrenamiento, el cual les indica cómo responder a cada situación que se le presente [Ponce, 2010].

Las redes neuronales artificiales consisten en un número finito de elementos procesadores de información llamados neuronas o nodos. Cada neurona está conectada con otras neuronas junto con sus respectivos pesos por cada conexión. Este peso es usado por las neuronas como herramienta para resolver problemas. Cada neurona cuenta con una función de activación la cual se aplica a la señal de entrada para generar una señal de salida. Las neuronas solo pueden mandar una señal a la vez. Esta señal puede ser mandada a varias neuronas a la vez [Hayking, 1999].

Usando una red de retro propagación hacia atrás [Fausett, 1994] junto con una serie de variables definidas en el problema, que servirán como alimento de la red neuronal artificial, se lograra obtener el resultado esperado, el cual es una señal de surtimiento rápida y confiable.

Actualmente no existe un sistema que convine las redes neuronales artificiales con alertas de surtimientos a líneas de producción. Este estudio representa una nueva contribución a la literatura.

Este programa tendrá la tarea de procesar ciertos datos relacionados con la producción. Con estos datos, se buscará generar salidas con el número de línea y monto del lote de producción para avisar y prevenir faltantes de materiales.

Dentro de los resultados se busca una señal de salida confiable proveniente de este sistema. El resultado esperado de esta investigación es probar de manera confiable el diseño de un sistema de surtimiento a líneas de producción a través de una red neuronal artificial. De manera que, si es posible, se identifiquen las variables que se deben de considerar para que el sistema funcione de manera rápida y eficaz.

2. Método

El objetivo demanda una propuesta formal de un sistema inteligente capaz de anticipar el agotamiento de insumos y evitar tiempos muertos en las líneas de producción. Dicha capacidad de anticipar será dada por señales de surtimiento hacia las líneas de producción. Estas señales serán mandadas en base a ciertas variables relacionadas al estado en el que se encuentra el material a surtir en tiempo real dentro de la línea.

Para encontrar las variables que sirvieron para alimentar al sistema inteligente, se examinó un proceso de una línea de producción genérico del cual se puntualizaron las características que intervienen en el agotamiento de material en una línea de producción [Lazarini, 2018]. Teniendo las variables identificadas, se prosiguió a fijar parámetros dentro de nuestro sistema inteligente, específicamente redes neuronales artificiales, que tuvieran un mejor desempeño con nuestro objetivo.

Al obtener los parámetros con el desempeño deseado en nuestra red neuronal artificial, se continuó con la generación de propuestas de arreglos de redes neuronales para poder satisfacer el objetivo de la demanda.

Variables que influyen en el agotamiento de material en líneas de producción

En base a la observación de una línea de producción genérica, se concluyó con cuatro variables capaces de trabajar en conjunto con el sistema inteligente para poder satisfacer el objetivo de la tesis. Dichos indicadores fueron:

- Plan maestro de producción correspondiente a una línea de producción.
- Tamaño deseado de lote Pitch de dicha línea [Villaseñor, 2007].
- Piezas en trabajo en proceso dentro de la línea.
- Piezas terminadas de dicha línea.

Estas variables servirán como alimentación de nuestra red neuronal artificial para entrenarla y poder obtener una red capaz de anticipar los agotamientos de material en la línea de producción. Las cuatro variables son medidas en piezas.

Cabe mencionar que estos parámetros tendrán que ser medidos en cada línea o grupos de líneas en los que se desee aplicar una red neuronal artificial de este tipo. Esto debido a las características que presentan los entrenamientos de las redes neuronales y sus resultados.

Elección de red neuronal artificial

Se eligió como red neuronal artificial de trabajo una red de retro propagación debido a que sus características y parámetros fueron las que mejor se adaptaron al problema en la experimentación. La teoría para encontrar los parámetros adecuados para el problema se llevó a la práctica en el ToolBox de redes neuronales en MatLab. Esta experimentación no está incluida en este trabajo debido a las limitaciones de este mismo, así que es una mera recomendación que está abierta a futuras experimentación. La experimentación arrojo que el uso óptimo de neuronas en la capa oculta es de cinco.

Al igual que la elección de la red neuronal a usar, después se experimentó con los parámetros y características de dicha red. Los parámetros mejor desempeñados a usar dentro del ToolBox de MatLab, son:

- Network Type: Feed-Forward backprop
- Training Function: TRAINLM
- Adaption learning function: LEARNGD
- Performance function: MSE
- Number of layer: 2
- Properties for layer 1: 5 neurons y PURELIN en Transfer Function.
- Properties for layer 2: LOGSIG en Transfer Function.

Todas estas características deben ser ingresadas al ToolBox de MatLab para obtener los resultados esperados. Así mismo, estas características de la red neuronal artificial deben ser iguales en cualquier ejemplo relacionado a este tema.

Entrenamiento de la red neuronal artificial

El entrenamiento es supervisado a causa del tipo de red neuronal que se eligió. Dicho entrenamiento se realizó por entradas en tiempo real de las cantidades de material dentro de cada variable. Estas etapas constan desde que la línea tiene que fabricar una cantidad determinada por el plan maestro de producción mientras las otras variables están en cero, hasta que la cuarta variable toma el valor de las piezas a producir en el plan maestro y la primera variable llega al valor cero.

En la tabla 1 se puede observar un ejemplo de cómo va evolucionando las entradas en tiempo real a la red neuronal hasta terminar el ejercicio. Tomando en cuenta que la línea de producción solo puede tener una pieza en trabajo por vez. Una nueva pieza solamente puede entrar a la línea cuando haya cero piezas en trabajo. Otra consideración será que se está trabajando con un solo tipo de materia prima y una sola línea. Todas estas consideraciones varían dependiendo al problema en cuestión. Cada columna en todas las tablas representa un ejercicio hecho con los datos proporcionados en dicha columna. Todas las entradas deben tener su respectiva salida esperada para su entrenamiento. En tabla 2 se muestra un ejemplo de la evolución de las salidas complementarias al ejercicio realizado en la tabla 1. Siendo las dos salidas el tamaño de lote a surtir y la línea a la cual va a dirigirse.

Tabla 1 Entradas para el entrenamiento de la red neuronal artificial.

Numero de casilla	1	2	3	4	5	6	7	8	9	10	11	12	13
Plan maestro de producción	6	6	6	5	4	4	4	3	2	2	2	1	0
Tamaño deseado de lote Pitch	0	2	1	0	0	2	1	0	0	2	1	0	0
Piezas en trabajo en proceso	0	0	1	1	0	0	1	1	0	0	1	1	0
Piezas terminadas	0	0	0	1	2	2	2	3	4	4	4	5	6

Tabla 2 Salidas para el entrenamiento de la red neuronal artificial.

Numero de casilla	1	2	3	4	5	6	7	8	9	10	11	12	13
Tamaño de lote a surtir	2	0	0	0	2	0	0	0	2	0	0	0	0
Línea a la cual surtir	1	1	1	1	1	1	1	1	1	1	1	1	1

Lo lógico sería indicar el surtimiento en el entrenamiento como se hizo en la tabla 2, sin embargo, las variables de entrada pueden tener prácticamente cualquier valor para cada caso en particular. Al fin de proteger el funcionamiento de este sistema, se recomienda que en el entrenamiento se surta un rango de entre el 15% y 35%

de las casillas en cada sección. Esta sección mencionada, es considerada cada vez que se manda la nueva señal de surtimiento del lote tipo Pitch a la línea de producción hasta que ese mismo lote tipo Pitch está totalmente fabricado (De la casilla 1 a la 5 se considera una sección, igual de la casilla 6 a la 9 y consecuentemente). El rango recomendado a surtir se mide del final de cada sección hacia el inicio de esta misma, esto sin contar la casilla surtida inicial de cada sección. En la tabla 2 se podría decir que se está contando con un 20% de surtimiento. En la tabla 3 se da otro ejemplo del mismo ejercicio, pero ahora con un 40% de surtimiento.

Tabla 3 Salidas alternas para el entrenamiento de la red neuronal artificial.

Numero de casilla	1	2	3	4	5	6	7	8	9	10	11	12	13
Tamaño de lote a surtir	2	0	0	2	2	0	0	2	2	0	0	0	0
Línea a la cual surtir	1	1	1	1	1	1	1	1	1	1	1	1	1

3. Resultados

Dentro del entrenamiento se detectó un fenómeno. Éste permite disminuir o aumentar la capacidad de anticipación de surtimiento de la red neuronal artificial. Esta capacidad es permitida si se aumenta o disminuye las casillas de surtimiento en cada sección dentro de las salidas de entrenamiento. Este fenómeno puede ser usado en favor del diseñador. Esto para poder programar su red neuronal artificial con cierta sensibilidad deseada hacia el surtir o no surtir y obtener anticipadamente este surtimiento en la línea de producción.

Red neuronal artificial

Como resultado del ejercicio realizado con el ToolBox de redes neuronales de MatLab, se logró obtener una red neuronal artificial. Esta red neuronal artificial tiene estabilidad y congruencia en sus salidas. Se logró obtener una red neuronal artificial con salidas esperadas.

Se creó una red neuronal artificial de retro propagación hacia atrás con una capa oculta, cinco neuronas de entrada y dos neuronas de salidas. Se utilizó la función de transferencia PURELIN en la capa de entrada y una Sigmoidal en la capa oculta.

Funcionalidad de la red neuronal artificial

Como resultado de la funcionalidad de la red neuronal artificial se obtuvieron resultados esperados los cuales se adaptaron totalmente a lo expuesto en la metodología. Se obtuvieron redes neuronales artificiales capaces de anticiparse a una necesidad de surtimiento de una línea de producción específica. Estas anticipaciones pueden ser parcialmente controladas con la metodología expuesta en el inicio del apartado 2.

Se pueden observar ejemplos de diferentes configuraciones de líneas de producción (las configuraciones van enfocadas a las cantidades dadas de cada variable involucrada en el ejercicio) en las que se puede analizar el fenómeno que se mencionó en la metodología del apartado 2 [Lazarini, 2018]. Esta referencia pertenece a un trabajo que será publicado a finales del año 2018.

4. Discusión

Actualmente no se han reportado después de una tarea exhaustiva de investigación, trabajos relacionados entre las redes neuronales artificiales y el mandar señales de agotamiento de material. Debido a esto, es un tema el cual se puede explotar para incluirlo como parte fundamental de la teoría que se está desarrollando en estos tiempos como lo es la empresa 4.0.

Los resultados son prometedores debido a que demuestra que la herramienta puede ser utilizada para este fin de manera efectiva. El artículo se limita solamente a la interacción de la red neuronal artificial con un ejemplo de línea de producción de un solo material como requerimiento de materia prima. Como tema independiente, es una investigación muy limitada y de poco sentido. No tiene uso en campo, pero, el complementar este estudio con propuestas que sigan esta misma rama de investigación puede generar resultados interesantes.

Conclusiones

Por medio de la red neuronal artificial se logró relacionar las variables de entrada con las salidas esperadas de la red. Se puede decir que esta investigación es el cimiento para todo un campo de investigación relacionado al tema. Estas

investigaciones en conjunto podrán ser usadas en campo y con ellas se podrá reducir el desperdicio de material, tiempo y esfuerzo dentro de las líneas de producción.

5. Revisores

Revisor 1

Nombre: José Israel Hernández Vázquez
Institución: TecNM / Instituto Tecnológico de León
Cédula Profesional: 8521871
Área de conocimiento: Manufactura
Correo electrónico: israel_leon12@hotmail.com

Revisor 2

Nombre: José Omar Hernández Vázquez
Institución: TecNM / Instituto Tecnológico de León
Cédula Profesional: 8521872
Área de conocimiento: Manufactura
Correo electrónico: blink_leoncampeon@hotmail.com

6. Bibliografía y Referencias

- [1] Chase, R. B., & Jacobs, F. R. (2008). Administración de operaciones y cadena de suministros. Ciudad de México: Mc Graw Hill.
- [2] Nomura, J. & Takakuwa, S. (2006). Optimization of a number of containers for assembly lines. International Journal of Simulation Modelling. ISSN 1726-4529.
- [3] Ponce Cruz, P. (2010). Inteligencia Artificial. Ciudad de México: Alfaomega.
- [4] Hayking, S. (1999). Neural Networks and Learning Machines. Ciudad de México: Pearson.
- [5] Fausett, L. (1994). Fundamentals of Neural Networks. New Jersey: Prentice Hall.
- [6] Villaseñor Contreras, A., & Galindo Cota, E. (2007). Manual de Lean Manufacturing. Ciudad de México: Limusa.
- [7] Lazarini Diaz Barriga, J. (2018) (Tesis). Sistema de un sistema de surtimiento de material a líneas de producción a través de una red neuronal artificial. Tecnológico Nacional de México en Celaya.