

SENSORES VIRTUALES CON FOUNDATION FIELDBUS

R. Ferreiro García

Dept. Ing. Industrial, E.S.Marina Civil, Paseo de Ronda 51, 15011 A Coruña, ferreiro@udc.es

A. Piñón Pazos,

Dept Ing. Industrial, andrespp@cdf.udc.es,

Resumen

Este trabajo describe a metodología para medir variables de difícil acceso o de captura costosa. El método propuesto consiste en utilizar redes de neuronas artificiales para estimar la dinámica de un proceso y posteriormente, después de entrenar el sistema neuronal, utilizar la citadas redes neuronales para representar tal dinámica. La herramienta de adquisición de datos y entrenamiento neuronal pertenece a Emerson Process Management, se denomina DeltaV y DeltaV Neural y cumple con los requisitos de l estándar Foundation Fieldbus.

Palabras Clave: Redes neuronales, Foundation Fieldbus, Aproximador universal.

1 INTROCCIÓN

Las redes neuronales artificiales (NN) se caracterizan por resolver problemas no lineales de aproximación funcional y esencialmente discontinuos en general. La implementación de un aproximador funcional no lineal es susceptible de realización por medios matemáticos, por ejemplo mediante funciones obtenidas por regresión multidimensional a partir de datos de entrada/salida de un determinado proceso, o alternativamente mediante mapeo de los datos de entrada/salida en memorias asociativas. Sin embargo la flexibilidad y la robustez de las NN así como la disponibilidad de técnicas eficaces de entrenamiento hacen que esta tecnología logre afianzarse y extenderse en aplicaciones de todos los campos de la ciencia y la tecnología. Así, como sensores de variables de acceso directo difícil o sensores con dependencia multivariable no lineal resultan útiles. En la siguiente sección se describen algunas aplicaciones de las NN a la implementación de sensores de variables, que por otra parte resultan de difícil captura por medios convencionales. Para llevar a cabo esta tarea de modo sistemático en entornos de control de procesos industriales se parte de la utilización de una aplicación de control [2], la cual opera bajo el estándar Foundation Fieldbus (FF) [4].

2 SENSORES VIRTUALES CON FOUNDATION FIELDBUS

Se propone la estimación de una variable de proceso, (virtual), partiendo de la información en tiempo real (o histórica) de variables relacionadas con el proceso, susceptible de influir sobre la variable virtual.

Conocida la dependencia entre variables de un proceso, su relación puede expresarse como

$$V_1 = f(V_2, V_3, \dots, V_N) \quad (1)$$

Donde V_1 es el consecuente, (variable de salida a determinar o variable virtual) y V_2, V_3, \dots, V_N son los antecedentes o variables de entrada susceptibles de medición o acceso.

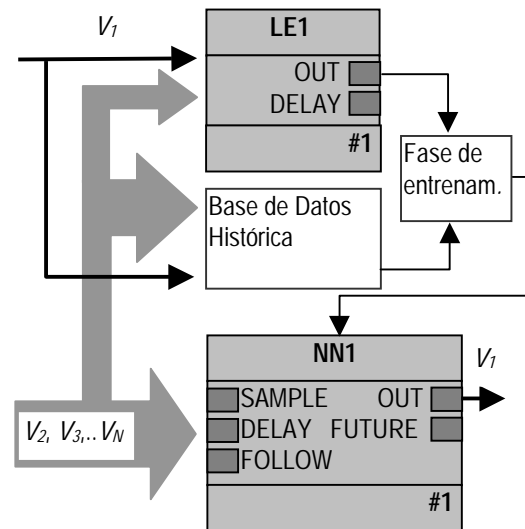


Fig. 1. Esquema de diseño e implementación del sensor virtual

La estimación del comportamiento del proceso en base a las variables descritas en la expresión (1) requiere un método de aproximación funcional. Un aproximador funcional universal lo constituyen las NN. Por tanto la construcción de un aproximador funcional con NN en base al estándar FF requiere asimismo de una herramienta de diseño e

implementación. Tal herramienta consiste en DeltaV Neural [3], una parte de la DeltaV, herramienta de diseño de sistemas de control bajo FF. La figura 1 ilustra el esquema del principio de concepción del sensor virtual, el cual consta de las fases de:

- ◆ captura y pre-procesamiento de información,
- ◆ entrenamiento y validación del sensor fuera de línea y
- ◆ fase de implementación y operación en línea.

El bloque función NN1 [3] de la figura 1 es utilizado para crear sensores virtuales capaces de predecir continuamente la salida de un proceso en base a la medida de entradas al proceso. Además, las NN1 calculan y proporcionan el valor futuro de la salida en base a los valores actuales de entrada de un bloque función. Se utiliza las NN1 en los casos en que la salida del proceso está solamente disponible por medio de muestras históricas o cuando no es posible la medida en línea.

El bloque función NN1 constituye la base de implementación de redes neuronales en los sistemas DeltaV. Se definen todos los parámetros en el bloque función NN desde la aplicación Control Studio.

El bloque función NN1 utiliza datos históricos (muestreados y acumulados mediante el bloque función LE) para el entrenamiento de la NN1. Después del entrenamiento, la NN1 utiliza la información muestreada de entrada para corregir automáticamente la salida calculada a cambios del proceso o entradas no medidas. La habilidad de la NN1 para adaptarse a cambios reduce el mantenimiento minimizando la necesidad de re-entrenamiento para compensar los cambios en el proceso.

Para entrenar y probar la NN1 se utiliza la aplicación DeltaV Neural. Cuando se utiliza un módulo conteniendo un bloque función NN1, todas las entradas y salidas son asignadas a la aplicación DeltaV Historian. El bloque función NN1 puede predecir la salida futura de un proceso dadas las entradas actuales.

El bloque función Lab Entry (LE1) de la figura 1 proporciona la forma de análisis fuera de línea de la información previamente adquirida en el sistema DeltaV, para ser utilizada fundamentalmente para entrenamiento de redes neuronales, por ejemplo en un módulo que incluya una red neuronal.

Para cada bloque función LE, se crea una interface del operador facilitando la interpretación de los resultados del análisis. El bloque LE1 computa el retardo entre el tiempo en que ha sido tomada las muestras y el tiempo en que el operador proporciona los resultados del análisis. Si tanto el valor de análisis

como el retardo calculado están dentro de los límites máximo y mínimo, se pasa el valor al parámetro OUT del bloque LE y pasa el retardo calculado a DELAY. Si alguno de estos valores queda fuera del rango establecido, emerge un diálogo negando la validaz de la información

El bloque función LE1 utiliza el status atributo límite de OUT para indicar cuando un operador ha introducido una nueva muestra. Después de que un operador haya entrado un nuevo valor, el bloque cambia su atributo límite de OUT de Constant a Not Limited por dos ejecuciones de bloque. Los bloques aguas abajo, pueden utilizar este status para detectar cuando el parámetro OUT contiene los resultados de un nuevo análisis. El bloque función LE1 soporta manipulación del status y del modo.

2.1 SENSOR VIRTUAL DE CAUDAL EN UN TRAMO CON VÁLVULA

Se propone la estimación del caudal que circula por un conducto, partiendo de la información en tiempo real del estado de una válvula (posición) y de la presión aguas arriba y abajo de la misma, susceptible de influir sobre el caudal

Se admite entonces que el caudal q es función de la posición de la válvula P_v , de la presión aguas arriba P_1 , y de la presión aguas abajo P_2 . Esta dependencia que es única para un determinado fluido en condiciones invariantes, se expresa como

$$q = f(P_v, P_1, P_2) \quad (2)$$

La figura 2 muestra la estructura del sistema de adquisición de información para crear un patrón de entrenamiento de la red neuronal (NN) que constituye un sensor virtual de caudal.




Fig. 2. Adquisición de datos para entrenamiento

En cada ciclo de muestreo, se captura el caudal, la presión antes de la válvula, la presión después de la válvula y la posición de la válvula, la cual puede ser dada en términos de la señal de actuación o alternativamente en valores de la posición del

servoactuador tanto en % del rango como en valor absoluto.

La base de datos necesaria para el entrenamiento del sensor virtual de caudal constituido por una NN presenta la estructura mostrada en la tabla 1. La información de esta base de datos es utilizada para el entrenamiento de la NN.

muestreo	$P1$	$P2$	Pv	q
ciclo i	$P1i$	$p2i$	pvi	qi
ciclo $i+1$	$P1i+1$	$P2i+1$	$Pv1+1$	$qi+1$
-----	----	----	----	----
ciclo $i+n$	$P1i+n$	$P2i+n$	$Pvi+n$	$qi+n$

Tabla .1 Base de datos patrón

Con la información acumulada en la base de datos bajo una estructura similar a la mostrada en la tabla.1, se procede al entrenamiento de una NN con tres señales de entrada y una salida. Una vez finalizada la fase de entrenamiento se implementa el sensor virtual de caudal en la forma mostrada en la figura 3. Si variasen las características del fluido, las del conducto, o las de la válvula, ya no sería posible la medida con la misma NN. Sería necesario crear una nueva base de datos para un nuevo patrón de entrenamiento y repetir la tarea. La figura 3 ilustra el sensor virtual de caudal con el sistema de captura de información en tiempo real necesaria para efectuar la medida de caudal en modo virtual.




Fig. 3. Estimación del caudal mediante una NN en base a la información de entrada en tiempo real.

2.2 SENSOR VIRTUAL DE CAUDA DE DESCARGA DE UN TANQUE

Se propone la estimación del caudal que circula por un conducto de descarga de un tanque, partiendo de la información en tiempo real del estado de una válvula (posición) y de la información aguas arriba y abajo de la válvula, susceptible de influir sobre el caudal. La información aguas arriba que se admite influye sobre el caudal de un determinado fluido, es la presión total debida a la asociación de la presión del recinto con la presión hidrostática debida al nivel.

Por otra parte, aguas abajo de la válvula debe existir cierta resistencia a la circulación, la cual está relacionada con la presión estática del fluido después de la válvula.

Se admite entonces que el caudal q es función de la posición de la válvula Pv , de la presión del recinto $P1$, de la presión hidrostática dada por el nivel $L1$ y de la presión aguas abajo de la válvula $P2$. Esta dependencia que es única para un determinado fluido en condiciones invariantes, se expresa como

$$q = f(Pv, P1, L1, P2) \quad (3)$$

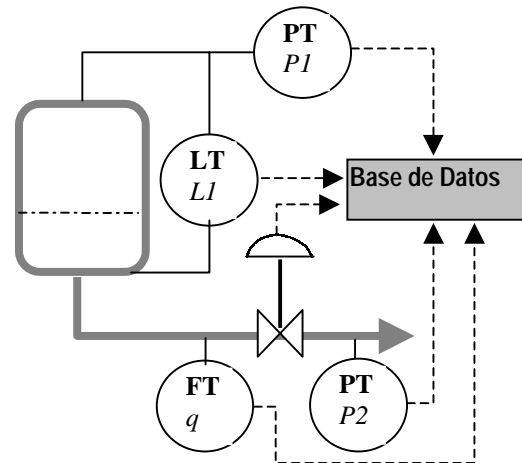


Fig. 4. Adquisición de datos para entrenamiento

La figura 4 muestra la estructura del sistema de adquisición de datos necesaria para obtener la información susceptible de utilizar como patrón de entrenamiento de una NN. El proceso de captura de información requiere un muestreo de todas las variables implicadas recorriendo el rango total de cada una a intervalos de medida de manera que represente la relación entre las entradas y salida con precisión. Cualquier variable que permanezca constante a lo largo de la recolección de información es irrelevante para el entrenamiento así como para la operación del sensor virtual. Por tanto tal variable debe ser excluida o descartada tanto del entrenamiento como de la operación del sensor, facilitando las tareas de entrenamiento y posterior aplicación a la medida. Por ejemplo si la presión aguas debajo de la válvula permanece constante, entonces esta variable debería ser descartada.

muestreo	Pv	$P1$	$L1$	$P2$	q
ciclo i	Pvi	$P1i$	$L1i$	$P2i$	qi
ciclo $i+1$	$Pvi+1$			$P2i+1$	$qi+1$
-----	----	----	----	----	----
ciclo $i+n$	$Pvi+n$			$P2i+n$	$qi+n$

Tabla 2 Base de datos patrón

La base de datos necesaria para el entrenamiento de la NN presenta la estructura mostrada en la tabla 2. Es utilizada para entrenamiento.

Una NN cuya arquitectura permita cuatro variables de entrada y una de salida es capaz de mapear la función propuesta mediante una etapa de entrenamiento con información en tiempo real o información histórica acumulada en una base de datos similar a la mostrada en la tabla 2.

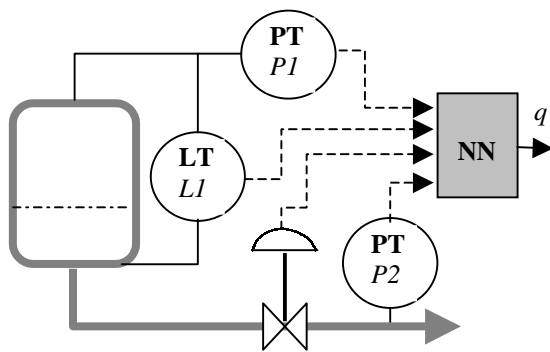


Fig. 5. Estimación del caudal de descarga mediante una NN en base a la información de entrada en tiempo real.

La cantidad de información necesaria para proporcionar el patrón de entrenamiento es suficiente cuando los rangos de existencia de las variables involucradas en la función propuesta hayan sido recorridos en su totalidad, de manera que cualquier combinación de valores que se puedan dar en la práctica hayan sido capturados y almacenados en la base de datos. Una vez acumulada suficiente información relevante se procede al entrenamiento de la NN para conseguir el sensor de caudal propuesto. En la figura 5 se muestra el sensor virtual de caudal en base a una NN entrenada.

2.3 SENSOR VIRTUAL DE CAUDAL EN PROCESOS DE TRANSFERENCIA DE FLUIDOS

Se propone la estimación del caudal que circula por un conducto, partiendo de la información en tiempo real del estado de una bomba (revoluciones/segundo) y de la presión aguas arriba y abajo de la misma. Se admite entonces que el caudal q es función de la presión de aspiración de la bomba $P1$, de la presión de descarga $P2$, y de la velocidad de rotación de la bomba W . Esta dependencia que es única para un determinado fluido en condiciones invariantes, se expresa como

$$(4)$$

La figura 6 muestra la estructura del sistema de adquisición de información para crear un patrón de entrenamiento de la NN que constituye un sensor virtual de caudal destinado a la medida del caudal e trasiego de una bomba. En cada ciclo de muestreo, se captura el caudal, la presión de aspiración (antes de la bomba), la presión de descarga (después de la bomba) y la velocidad de rotación de la bomba.

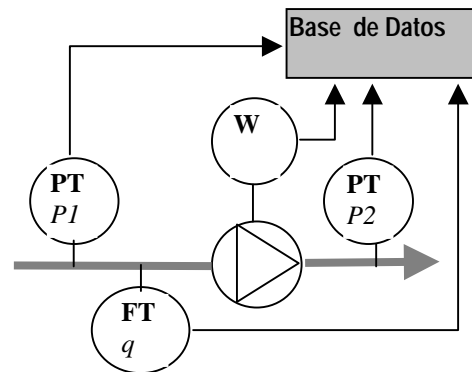


Fig. 6. Adquisición de datos para entrenamiento

La base de datos necesaria para el entrenamiento de la NN presenta la estructura mostrada en la tabla 3. Esta información es utilizada para entrenamiento de la NN.

muestreo	P1	P2	W	q
ciclo i	P1i	P2i	Wi	qi
ciclo i+1	P1i+1	P2i+1	Wi+1	qi+1
-----	----	----	----	---
ciclo i+n	P1i+n	P2i+n	Wi+n	qi+n

Tabla .3 Base de datos patrón




Fig. 7. Estructura del sistema de medición de caudal mediante el sensor virtual.

Con la información de la tabla 3 se entrena la NN destinada a servir de sensor de caudal de impulsión de la bomba. La figura 7 muestra la estructura del sensor virtual de caudal de la bomba.

2.4 SENSOR DE FUERZA DE EMPUJE DE UN PROPULSOR HELICOIDAL

El empuje de un propulsor helicoidal (hélice), puede ser expresado en función de la velocidad de rotación W , el paso del propulsor helicoidal Ph y de la velocidad de desplazamiento respecto del vehículo V .

$$E = f(W, Ph, V) \quad (5)$$

Siguiendo la misma técnica que en los casos descritos anteriormente, se obtiene una base de datos patrón destinada al entrenamiento de la NN que constituye el sensor virtual de empuje.

2.5 SENSOR DE ÍNDICE DE CARGA DE UN MOTOR ALTERNATIVO DE COMBUSTIÓN

El índice de carga Ic de un motor de combustión es una función del caudal de combustible Qc , de la temperatura T de exhaustación y de la velocidad de rotación W .

$$Ic = f(W, Qc, T) \quad (6)$$

Esta función es mapeada mediante un proceso de adquisición y almacenamiento de datos, que posteriormente serán utilizados como patrón de entrenamiento del sensor virtual de índice de carga. La base de datos necesaria para el entrenamiento de la NN presenta la estructura mostrada en la tabla 4. Esta información es utilizada para entrenamiento de la NN.

<i>muestreo</i>	<i>Qc</i>	<i>T2</i>	<i>W</i>	<i>Ic</i>
ciclo i	Qci	T2i	Wi	Ici
ciclo i+1	Qci+1	T2i+1	Wi+1	Ici+1
-----	----	----	----	---
ciclo i+n	Qci+n	T2i+n	Wi+n	Ici+n

Tabla .4 Base de datos patrón

3 CONCLUSIONES

Se han presentado diversas aplicaciones industriales de sensores virtuales. Son numerosas las aplicaciones susceptibles de realización, pero solamente tienen justificación aquellas aplicaciones en las que el acceso directo a la información vía captura y procesamiento es imposible o resulta demasiado costosa. Los ejemplos propuestos ilustran el método a utilizar con los medios citados. Sin tales herramientas la tarea de diseño e implementación de un sensor virtual resulta ardua.

Referencias

- [1] Caudill, M., and C. Butler, (1992) Understanding Neural Networks: Computer Explorations, Vols. 1 and 2, Cambridge, MA: the MIT Press.
- [2] Fisher-Rosemount Software DeltaV, V5.3.1 (2001), Austin, TX 78754 USA. www.EasyDeltaV.com
- [3] Fisher-Rosemount Reference Books (2001), Austin, TX 78754 USA. www.EasyDeltaV.com
- [4] Foundation Fieldbus. Technical Overview (2003) www.Fieldbus.org