

Identificación de un Robot Cilíndrico utilizando Redes Neuronales Recurrentes

Velázquez Velázquez Juan Eduardo¹, Mariaca Gaspar Carlos Román,
Galván Guerra Rosalba y Ortiz Rodríguez Floriberto

Escuela Superior de Ingeniería Mecánica y Eléctrica Unidad Zacatenco - Instituto Politécnico Nacional
Av. Instituto Politécnico Nacional s/n, Unidad Profesional "Adolfo López Mateos",
Edif. 1, 2, 3, 4 y 5, Col. Lindavista, Del. Gustavo A. Madero, México, D.F. C.P. 07738

¹Autor de correspondencia: jvelazquez@ctrl.cinvestav.mx, Teléfono: (52)-55-57296000 ext 54871

Resumen

Las técnicas de identificación neural son muy útiles para el problema de dinámicas desconocidas e incertidumbres durante la elaboración de un modelo que represente de forma precisa el comportamiento de un robot. En este trabajo se propone la utilización del modelo de una Red Neuronal Recurrente Entrenable (RNRE) para el modelado de un robot cilíndrico. La RNRE propuesta consiste en una red multicapa con retroalimentación local en la única capa oculta, para aproximar a la dinámica del robot. El algoritmo de aprendizaje para esta topología es el backpropagation (BP) dinámico. Los resultados de la simulación gráfica de dicha aproximación obtenida a través de la RNRE, mostraron una buena convergencia y un seguimiento preciso.

Palabras clave: Redes Neuronales, Identificación de sistemas, Robots manipuladores.

1. Introducción

En general, los robots manipuladores pertenecen a la clase de sistemas no lineales y variantes del tiempo. Para estos manipuladores los controladores que se utilizan para gobernar su comportamiento son de tipo avanzado y robusto que requieren necesariamente algún conocimiento sobre el comportamiento dinámico del sistema bajo control [1]. En el caso de los robots manipuladores, la mayoría de las veces es difícil obtener información paramétrica importante, como la matriz de inercia y centros de masa de las articulaciones con suficiente precisión. Los efectos de la fricción y la inercia, por ejemplo, dependen del estado del sistema, aunado a la adición de cargas, pueden afectar el comportamiento dinámico en general. En este contexto, la técnica de identificación

neural ofrece la posibilidad de aprender comportamientos no lineales a través de la presentación de patrones de entrenamiento entrada/salida adecuados para ayudar a superar las dificultades antes mencionadas. Como se informa en la literatura, los resultados de diversos estudios demuestran que las redes neuronales artificiales (RNA) parecen ser una herramienta muy eficaz para la identificación y control de sistemas no lineales cuando se tiene información parcial o nula sobre ellos [2]. La capacidad para aproximar la compleja relación no lineal sin conocimiento previo de la estructura del modelo hace a la RNA una alternativa muy atractiva para el modelado clásico y técnicas de control. Esta propiedad ha sido demostrada por el teorema de aproximación universal [3]. Las arquitecturas de red más utilizadas son la Red Neuronal Feedforward (RNFF) y la Red Neuronal Recurrente (RNR). En una RNFF las señales se transmiten en una sola dirección, a partir de la capa de entrada y posteriormente, a través de las capas ocultas de la capa de salida, y se requiere la aplicación de retardos unitarios globales para lograr una relación no lineal auto-regresiva promedio del modelo del robot. Una RNR tiene conexiones de retroalimentación local en algunas de sus capas ocultas. Esta estructura es una alternativa adecuada a la RNFF cuando la tarea es elaborar el modelo de un sistema dinámico. Como se mencionó anteriormente, la principal ventaja de la RNR en el modelado de un robot es su capacidad de aprender de forma adaptativa funciones no lineales, cuyas formas de análisis son difíciles de obtener y cuyas soluciones son difíciles de calcular. Este hecho se refleja en el uso difundido de enfoques neuronales en problemas de robótica, ver por ejemplo [4], [5], [6]. En la mayoría de estas obras se manifiesta el inconveniente de utilizar RN estáticas de orden superior pues tienen una gran complejidad que hace difícil su aplicación. En [7], [8] [9], Baruch et al. define la arquitectura de

la Red Neuronal Recurrente Entrenable (RNRE) con un algoritmo de aprendizaje backpropagation (BP) dinámico que ha simplificado el problema en aplicaciones de identificación y control de diferentes plantas de naturaleza mecánica o biotecnológica. En el presente trabajo, esta RNRE se utiliza para una identificación no paramétrica de un robot cilíndrico modelado por un conjunto de ecuaciones diferenciales no lineales de segundo orden. El esquema del documento es el siguiente: En la sección 2 se introduce un modelo analítico que describe la dinámica del cuerpo rígido de un robot manipulador cilíndrico. En la sección 3 se presenta la descripción de la RNRE y el algoritmo de aprendizaje. En la sección 4 se presentan los resultados de simulación de la identificación de plantas utilizando RNRE. Finalmente, la sección 5 reúne las conclusiones del documento.

2. Modelo analítico de un Robot Cilíndrico y formulación del problema

Se han desarrollado una gran variedad de métodos para derivar las ecuaciones que representan la dinámica de un robot manipulador. En esta sección se presenta un conjunto general de las ecuaciones diferenciales que describen la evolución temporal de un robot cilíndrico. Estas son las ecuaciones de Euler-Lagrange de movimiento.

La formulación de Lagrange se basa en las coordenadas generalizadas de fuerza y energía. Si el manipulador se mueve libremente en el espacio de trabajo, entonces la ecuación dinámica del movimiento de un grado de libertad del robot se da en la forma de la siguiente matriz de movimiento de n grados de libertad:

$$M(q)\ddot{q} + C(q, \dot{q})\dot{q} + G(q) = \tau \quad (1)$$

donde τ es el vector de torque generalizado de dimensión $n \times 1$ aplicado a las articulaciones o juntas; q , \dot{q} y \ddot{q} son el vector de variables de las juntas del robot manipulador, su primera y segunda derivada, respectivamente. El primer término $M(q)$ es la matriz de inercias de dimensión $n \times n$. El segundo término $C(q, \dot{q})$ es la matriz de fuerzas centrífugas y de Coriolis. El último término $G(q)$ es el vector $n \times 1$ que representa la acción de las fuerzas gravitacionales.

El robot es un manipulador cilíndrico de tres grados de libertad, incluyendo dos articulaciones prismáticas y una articulación rotacional. Las

variables comunes son las coordenadas cilíndricas del efector final con respecto a la base. La configuración cilíndrica se muestra en la figura. 1.

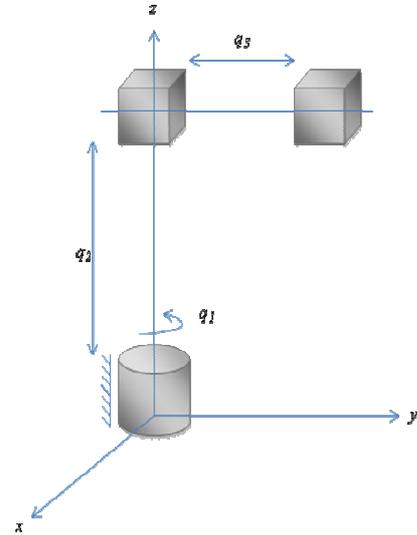


Fig. 1. Configuración del robot cilíndrico.

En este caso, el vector de coordenadas generalizadas es $q = [q_1, q_2, q_3]^T$. Siguiendo la metodología de Euler-Lagrange se obtiene la matriz de inercia siguiente

$$M(q) = \begin{bmatrix} I_{1zz} + I_{2yy} + I_{3yy} + m_3 q_3^2 & 0 & 0 \\ 0 & m_2 + m_3 & 0 \\ 0 & 0 & m_3 \end{bmatrix} \quad (2)$$

La matriz de fuerzas de Coriolis es

$$C(q, \dot{q}) = \begin{bmatrix} m_3 q_3 \dot{q}_3 + f_{fric-1} & 0 & m_3 q_3 \dot{q}_1 \\ 0 & f_{fric-2} & 0 \\ -m_3 q_3 \dot{q}_1 & 0 & f_{fric-3} \end{bmatrix} \quad (3)$$

El vector de fuerzas gravitacionales es $G(q) = [0, 0, 0]^T$ y el vector de torque es $\tau = [\tau_1, f_2 - (m_2 + m_3)g, f_3]^T$. Aquí q_1 , q_2 y q_3 denotan la posición angular de la junta rotacional y el desplazamiento de las dos juntas prismáticas, respectivamente. Para $i = 2, 3$, m_i denota la masa de cada eslabón del robot manipulador, localizadas al centro de cada eslabón. $I_{1zz}, I_{2yy}, I_{3yy}$ son los tensores de inercia del eslabón i alrededor del centro de masa del eslabón i . τ_1 , f_2 y f_3 denotan el

torque y las fuerzas verticales y horizontales, respectivamente. g es la aceleración debida a la acción de la gravedad. f_{fric-i} denota la fuerza de fricción en la junta i . Cabe mencionar que siguiendo el procedimiento Newton-Euler se llega al mismo modelo dinámico del el robot cilíndrico [10].

Ahora, considerando que $y = [q, \dot{q}]^T$ es la salida del sistema dinámico del manipulador (1) cuando un vector generalizado de torque τ es aplicado al robot cilíndrico, formulamos entonces el problema de identificación:

Problema 1: Supongamos que la ecuación dinámica del movimiento (1) para el robot manipulador cilíndrico se desconoce. El problema de identificación consiste en obtener un modelo que nos permita inferir cómo el robot manipulador cilíndrico responderá a otras entradas todavía desconocidas mediante la aproximación de la trayectoria de salida del manipulador del sistema. Es decir, para un experimento de duración t_f , deseamos determinar un modelo con una salida $\hat{y} = [q, \dot{q}]^T$ que aproxime la respuesta, utilizada durante el experimento, utilizando únicamente los datos observados $\{\tau, y, t \in [0, t_f]\}$.

3. Descripción de la topología de la RNRE y su aprendizaje

Con la ayuda del método diagramático [11] y siguiendo la figura 2, presentamos la topología de una RNRE descrita en forma vector-matriz como

$$\begin{aligned} \hat{x}(k+1) &= A\hat{x}(k) + B\hat{u}(k), \\ \hat{y}(k) &= F[v(k)], \end{aligned} \quad (4)$$

donde $v(k) = Cz(k)$, $z(k) = G[\hat{x}(k)]$; $F[\cdot]$ y $G[\cdot]$ vectores de funciones de activación; \hat{y} , \hat{x} , \hat{u} son los vectores de salida, estado y entrada de la RNRE con dimensión p , N , $n+1$, respectivamente; aquí $\hat{u}^T = [\tau, u_0]$, donde τ es el vector generalizado de torque de entrada y $u_0 = -1$ es una entrada de umbral; Aquí el vector de salida de la planta y es considerado como la salida de referencia para la RNRE; A es una matriz de dimensión $N \times N$ diagonal a bloques, definida

como $A = block - diag(A_i)$; $B = [B_1, B_0]$ y $C = [C_1, C_0]$ son matrices aumentadas $N \times (m+1)$ and $L \times (N+1)$ respectivamente; B_0 y C_0 son vectores de umbrales de dimensión $N \times 1$ y $L \times 1$ de las capas ocultas y de salida respectivamente.

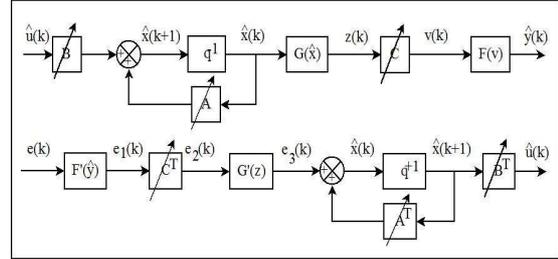


Fig. 2. Diagrama a bloques de la RNRE y su versión adjunta.

El algoritmo de aprendizaje asociado se describe como:

$$\begin{aligned} w(k+1) &= w(k) + \eta \Delta w(k) + \alpha \Delta w_{ij}(k-1), \\ e(k) &= y(k) - \hat{y}(k), \end{aligned} \quad (5)$$

donde w es una matriz generalizada de pesos denotando a cada una de las matrices (A, B, C) en el modelo de la RNRE, a ser actualizadas; Δw $(\Delta A, \Delta B, \Delta C)$, es la corrección de w (A, B, C) ; η , α son parámetros de aprendizaje; e , (e_1, e_2, e_3) son vectores de error de dimensiones apropiadas, calculados a partir del modelo adjunto de la RNRE (fig. 2). La corrección de pesos asociada y los correspondientes vectores de error son:

$$\begin{aligned} e_1(k) &= F'[\hat{y}(k)]e(k), \\ \Delta C(k) &= e_1(k)z^T(k), \\ e_2(k) &= C^T(k)e_1(k), \\ e_3(k) &= G'[z(k)]e_2(k), \\ \Delta B(k) &= e_3(k)\hat{u}^T(k), \\ \Delta A(k) &= e_3(k)\hat{x}^T(k), \end{aligned} \quad (6)$$

donde $F'[\hat{y}(k)] = [1 - \hat{y}^2(k)]$ y $G'[z(k)] = [1 - z^2(k)]$ son las derivadas de las funciones de activación; la estabilidad de la RNRE es asegurada mediante el

acotamiento debido a las funciones de activación dentro del intervalo $(-1,1)$ y a la condición de estabilidad local impuesta sobre la matriz de pesos, $|A_i| < 1$.

4. Resultados de simulación de la identificación del robot cilíndrico utilizando RNRE

Bajo la premisa del problema 1, esta sección está dedicada a obtener una RNR para aproximar la dinámica del robot. Aquí hacemos uso de la RNRE definida en (4), (5) y (6) establecida en el apartado anterior. El diagrama de bloques del proceso de identificación se ilustra en la figura. 3.

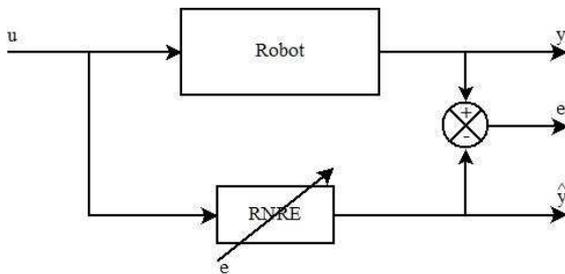


Fig. 3. Diagrama a bloques del modelo de identificación.

Para propósitos de simulación se usaron los siguientes valores de parámetros: $g = -9.8(ms^{-2})$, $I_{1zz} + I_{2yy} + I_{3yy} = 2.5(kgm^2)$, $m_2 = 5(kg)$, y $m_3 = 2.5(kg)$ tomados de la literatura [10]. También fue considerado que $f_{fric-1} = 0.1(kgs^{-1})$, $f_{fric-2} = 0.2(kgs^{-1})$ y $f_{fric-3} = 0.3(kgs^{-1})$, así como un tiempo de duración $t_f = 50(s)$ con un tamaño de tiempo de muestreo de $t_s = 0.01(s)$. El vector generalizado de torque de entrada se tomó como $\tau = [\tau_1, f_2 - (m_2 + m_3)g, f_3]^T$ donde

$$\tau_1 = 5 \sin\left(\frac{\pi}{4}t\right),$$

$$f_2 = \frac{\pi}{3}(1 - e^{-2t^3}) + \frac{\pi}{6}(1 - e^{-2t^3})\sin(3t), \quad (7)$$

$$f_3 = \frac{\pi}{2}(1 - e^{-2t^3}) + \frac{\pi}{3}(1 - e^{-2t^3})\sin(2t).$$

En orden de obtener datos experimentales apropiados $\{\tau, y, t \in [0, t_f]\}$ implementamos una acción de retroalimentación de estado a lo largo del vector de entrada τ , los datos obtenidos se muestran en la figura. 4 y la figura. 5.

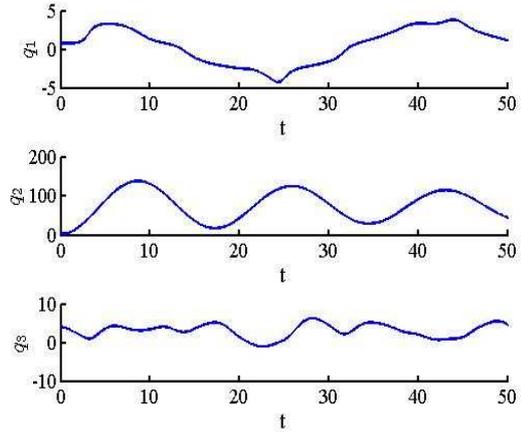


Fig. 4. Variables generalizadas de posición de las juntas del robot manipulador.

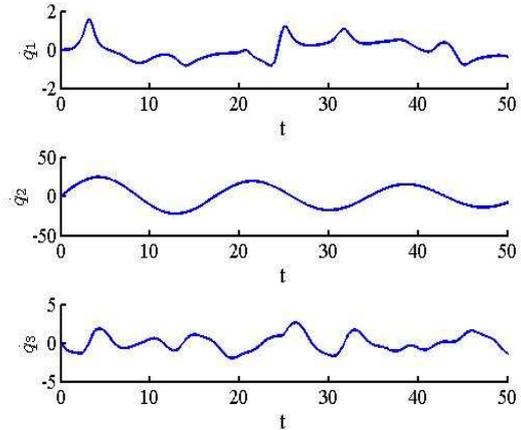


Fig. 5. Variables generalizadas de velocidad de las juntas del robot manipulador.

Tenga en cuenta que el rango de las funciones de activación $\tanh(\cdot)$ se encuentra en el intervalo $[-1,1]$. Luego, para aproximar funciones con un rango fuera de dicho intervalo es necesario normalizar tales funciones; de otra manera, la RNRE no podrá aproximar funciones fuera del rango $[-1,1]$. Así, la trayectoria de salida del robot cilíndrico es normalizada.

Ahora, el sistema (1)-(3) es considerado como un sistema no-lineal de dinámica desconocida. Proponemos una RNRE para aproximar dicha dinámica, utilizando una topología de la RNRE de (4-10-6) (4 entradas, 10 neuronas en la capa oculta, 6 salidas). Los parámetros de velocidad de aprendizaje para el algoritmo de aprendizaje BP son $\alpha = 0.1$, $\eta = 0.001$.

Los resultados de simulación de identificación utilizando la RNRE son obtenidos en línea durante un tiempo de simulación de 100(s) con un tamaño de paso de 0.01(s). Las entradas de identificación están definidas por (7) con un tiempo final $t_f = 100(s)$. Cabe mencionar que fue obtenida la evolución de \hat{q} comparada contra sus correspondientes señales de referencia q mostradas en la Fig. 6.

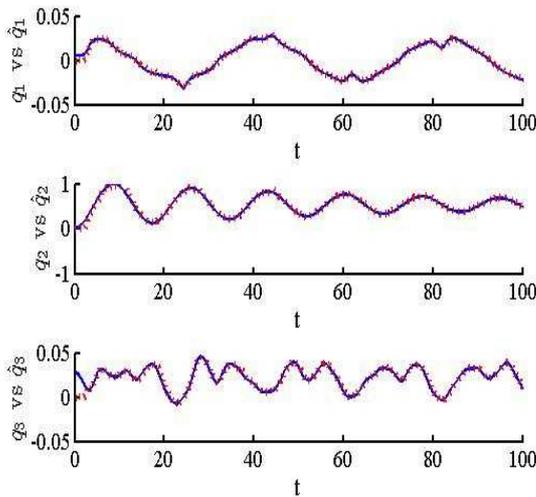


Fig. 6. Identificación de la posición de las juntas del robot: referencia (línea sólida) y su estimado (línea punteada)

En la Fig. 7 presentamos los resultados de la identificación de la velocidad $\hat{\dot{q}}$ comparada con su correspondiente señal de referencia \dot{q} .

Los resultados de la simulación muestran la eficacia de la RNRE propuesta. Esto se observa mejor en la gráfica del índice de desempeño dada en términos del error medio cuadrático, donde se obtiene una alta precisión de convergencia, ver fig. 8.

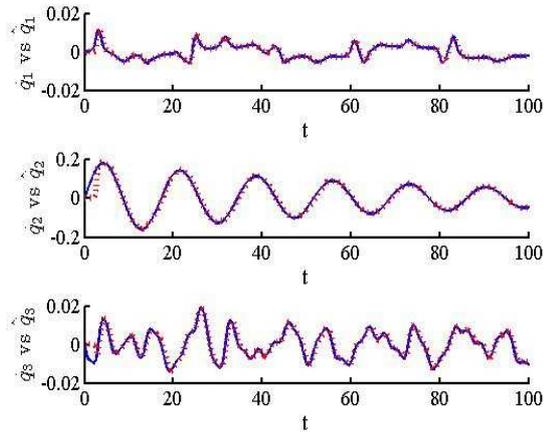


Fig. 7. Identificación de la velocidad de las juntas del robot: referencia (línea sólida) y su estimado (línea punteada)

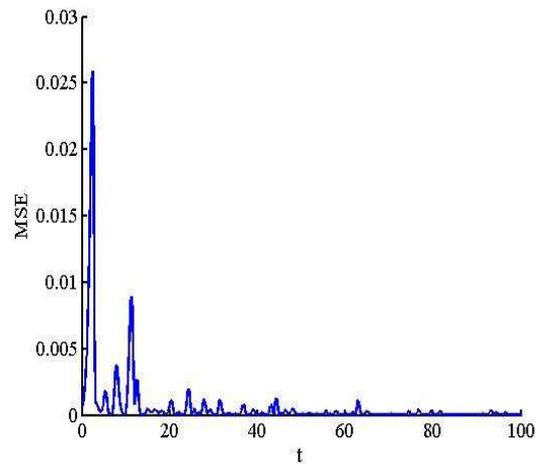


Fig. 8. EMC obtenido utilizando la RNRE propuesta

5. Conclusiones

En este trabajo se resuelve el problema de identificación de un robot manipulador cilíndrico mediante el uso de las RNRE. El uso de las RN permite obtener un modelo que permite inferir cómo el robot manipulador cilíndrico responderá a entradas desconocidas. La eficiencia del algoritmo propuesto se ilustra en las simulaciones donde se observa un seguimiento preciso y una convergencia aceptable. El contar con un modelo que predice el comportamiento del robot cuando no se tiene un modelo descrito por un conjunto de ecuaciones diferenciales permitirá el desarrollo de controladores que a su vez utilizarán los

beneficios de las RNRE para gobernar el comportamiento del robot manipulador sin necesariamente contar con algún conocimiento sobre el comportamiento dinámico del sistema bajo control.

6. Agradecimientos

Los autores agradecen el apoyo brindado a la Secretaría de Investigación y Posgrado del IPN (SIP-IPN), Comisión de Operación y Fomento de Actividades Académicas del IPN (COFAA-IPN), al Consejo Nacional de Ciencia y Tecnología (CONACyT).

Referencias

- [1] M. W. Spong and M. Vidyasagar, *Robot Dynamics and Control*. John Wiley and Sons, 1989.
- [2] K. S. Narendra and K. Parthasarathy, "Identification and control of dynamic systems using neural networks", *IEEE Trans. Neural Networks*, vol. 1, pp. 4-27, 1990.
- [3] S. Haykin, *Neural Networks a Comprehensive Foundation*, Upper Saddle River: Prentice Hall, 1999.
- [4] B. Horne, M. Jamshidi and N. Vadiiee, "Neural Networks in Robotics: a Survey ", *Journal of Intelligent and Robotic Systems*, vol. 3, pp.51-66, 1990.
- [5] S. S. Ge, T. H. Lee and C. J. Harris, *Adaptive Neural Network Control of Robotic Manipulators*, World Scientific Publishing Co, 1998.
- [6] H. D. Patino, R. Carelli and B. R. Kuchen, "Neural Networks for advanced control of robot manipulators", *IEEE Trans. Neural Networks*, vol. 13, pp. 343-354, 2002.
- [7] I. S. Baruch, J. M. Flores, F. Nava, I. R. Ramirez, and B. Nenkova, "An Advanced Neural Network Topology and Learning, Applied for Identification and Control of a D.C. Motor", in *Proc. 2002 1st Int. IEEE Symp. Intelligent Systems*, pp. 289-295.
- [8] I. Baruch, J. Barrera-Cortes, and L. A. Hernandez, "A Fed-Batch Fermentation Process Identification and Direct Adaptive Neural Control with Integral Term", in *MICAI 2004: Advances in Artificial Intelligence*, LNAI, vol. 2972, R. Monroy, G. Arroyo-Figueroa, L. E. Sucar, H. Sossa, Eds. Berlin, Heidelberg, New York: Springer-Verlag, 2004, pp. 764-773.
- [9] I. Baruch, P. Georgieva, J. Barrera-Cortes, and S. Feyo de Azevedo, "Adaptive Recurrent Neural Network Control. of Biological Wastewater Treatment", *International Journal of Intelligent Systems*, Wiley Periodicals, Inc., N. J., vol. 20, pp. 173-194, 2005.
- [10] P. Khosla and T. Kanade, "An Algorithm to Estimate Manipulator Dynamics Parameters", Institute for Software Research. Paper 653, 1987.
- [11] E. Wan and F. Beaufays, "Diagrammatic Method for Deriving and Relating Temporal Neural Networks Algorithms", *Neural Computations*, vol. 8, pp. 182-201, 1996.