

Control Neuronal Óptimo Inverso con Gradiente de Velocidad para un Sistema Eléctrico de Potencia

Enrique Alan Lastire Olmedo¹, Alma Y. Alanis² y Edgar Nelson Sánchez¹
¹CINVESTAV, Unidad Guadalajara, Apartado Postal 31-438, Plaza La Luna,
Guadalajara, Jalisco C.P. 45091. México, e-mail:
elastire@gdl.cinvestav.mx
²CUCEI, Universidad de Guadalajara, Apartado Postal 51-71, Col. Las
Águilas, C.P 45080, Zapopan, Jalisco, México, email:
almayalanis@gmail.com

Resumen—En este trabajo se presenta un controlador neuronal óptimo inverso con gradiente de velocidad en tiempo discreto para la estabilización de un sistema multi-máquina de potencia ante la presencia de una falla en una de las líneas de transmisión, para esto se propone un modelo neuronal reducido entrenado mediante el filtro de Kalman extendido.

Palabras clave: Redes neuronales de alto orden, Filtro de Kalman extendido, Control Óptimo, Generadores síncronos.

I. INTRODUCCIÓN

Las redes neuronales de alto orden nos permiten la identificación de un sistema no lineal, el cual en este caso es el estudio del sistema multi-máquina de potencia ante una falla, es por ello que en este trabajo se hace uso de sus ventajas para el diseño de nuestro controlador.

Existen diversos trabajos sobre generadores síncronos en los cuales se han propuesto modelos reducidos, cuyo propósito es la producción y distribución de energía eléctrica de manera confiable y robusta (M. A. Arjona, R. Escarela-Perez, G. Espinosa-Perez, J. Alvarez-Ramirez, 2009), (V. H. Benítez Baltazar, 2010). Por otro lado se ha propuesto un modelo en tiempo discreto (A. Y. Alanis, E. N. Sánchez and F. O., 2011) al cual se ha incorporado una red neuronal de alto orden para la implementación de una ley de control, este modelo reducido nos permite el estabilizar el sistema mediante la ley de control óptimo inverso GV (Gradiente de Velocidad). En el presente trabajo se toma como experiencia previa lo antes mencionado, se propone un modelo neuronal del sistema multi-máquina reducido, el cual resulta útil debido a que se centra en los estados que tiene mayor relevancia para este trabajo, como lo son la posición, velocidad y voltaje del rotor, posteriormente se implementa una ley de control para dicho sistema que consta de tres generadores síncronos interconectados. El presente artículo muestra una solución para el problema de des-estabilización que presenta el sistema multi-máquina de potencia ante

una falla, está ocurre a los 10 segundos en una línea de transmisión. Se presenta la identificación del el sistema multi-máquina de potencia de orden completo por medio de un modelo neuronal de orden reducido, el cual permite el diseño de la ley de control óptimo inversa GV. Por último se muestran los resultados obtenidos de la simulación, en los cuales se puede observar que la ley de control estabiliza el sistema ante la falla mencionada anteriormente.

II. DISEÑO DE CONTROLADOR

A. Control óptimo inverso: Enfoque por función candidata de Lyapunov

En este trabajo, una función candidata FCL es usada para sintetizar la ley de control óptimo inverso. Establecemos las siguientes asunciones y definiciones que permiten una solución al control óptimo inverso mediante un enfoque vía FCL.

Suposición 1: El estado completo del sistema

$$x(k+1) = f(x(k)) + g(x(k))u(k) \quad (1)$$

es medible.

Definición 1: (Ley de control óptimo inverso)
Definamos la ley de control (F. O. Tellez, 2011)

$$u(k) = -\frac{1}{2}R^{-1}(x(k))g^T(x(k))\frac{\partial V(x(k+1))}{\partial x(k+1)} \quad (2)$$

para ser óptimo inverso (globalmente) estabilizante si:

1. Si alcanza estabilidad asintótica (global) $x=0$ para el sistema (1)
2. $V(x(k))$ (es radialmente no acotada) una función definida positiva tal que satisface la desigualdad

$$\bar{V} := V(x(k+1)) - V(x(k)) + u(k)^T R(x(k))u(k) \leq 0 \quad (3)$$

Por otro lado cuando seleccionamos $l(x(k)) := \bar{V} \geq 0$; entonces $V(x(k))$ es una solución para la ecuación HJB

$$l(x(k) + V(x(k+1))) - V(x(k)) + \frac{1}{4}V^{T*}R^{-1}(x(k))g^T(x(k))V^* = 0 \quad (4)$$

donde

$$V^{T*} = \frac{\partial V^T(x(k+1))}{\partial x(k+1)} \text{ y } V^* = \frac{\partial V(x(k+1))}{\partial x(k+1)}$$

Como se estableció en la definición (1), el problema del control óptimo inverso está basado en el conocimiento de $V(x(k))$. Entonces, proponemos una FCL $V(x(k))$, tal que (1) y (2) son garantizadas. Esto es, en lugar de resolver (4) para $V(x(k))$, proponemos una función de control de Lyapunov $V(x(k))$ con la forma:

$$V(x(k)) = \frac{1}{2}x^T(k)Px(k) \quad (5)$$

para la ley de control (2), para poder asegurar estabilidad en el punto de equilibrio $x(k) = 0$ del sistema (1), que será alcanzado definiendo una matriz P apropiada. Establecemos la ley de control (2) con (5), la cual es referida como la ley de control óptimo inverso, que optimiza el funcional de costo de la forma:

$$J(x(k)) = \sum_0^{\infty} (l(x(k)) + u^T(k)R(x(k))u(k)) \quad (6)$$

Consecuentemente, considerando $V(x(k))$ como en (5), la ley de control toma la siguiente forma:

$$\begin{aligned} \alpha(x(k)) &:= u(k) \\ &= -\frac{1}{2}(R(x(k)) + P_2(x(k)))^{-1}P_1(x(k)) \end{aligned} \quad (7)$$

donde $P_1(x(k)) = g^T(x(k))Pf(x(k))$ y $P_2(x(k)) = \frac{1}{2}g^T(x(k))Pg(x(k))$. Vale la pena mencionar que P y $R(x(k))$ son matrices definidas positivas y simétricas, así la existencia de la inversa en (7) esta asegurada.

B. Algoritmo de gradiente de velocidad GV

Dado (7) redefinimos P como $P(k)$ donde $P_1(x(k)) = g^T(x(k))P(k)f(x(k))$ y $P_2(x(k)) = \frac{1}{2}g^T(x(k))P(k)g(x(k))$. Esto nos permitirá calcular un valor variante en el tiempo para $P(k)$, lo cual asegura estabilidad para el sistema (1) mediante el algoritmo GV. En (A. L. Fradkov and A. Y. Pogromsky, 1998) una aplicación en tiempo discreto para el algoritmo de gradiente de velocidad es formulada para encontrar una ley de control $u(k)$ que asegura la meta del control:

$$Q(x(k+1)) \leq \Delta \quad , \quad \text{para } k \geq k^* \quad (8)$$

donde Q es una función de control objetivo, una constante $\Delta > 0$ y $k^* \in \mathbb{Z}^+$ es el tiempo al cual la meta del control es alcanzada. Q asegura estabilidad si es una función definida positiva. Basado en la aplicación propuesta en (A. L. Fradkov and A. Y. Pogromsky, 1998), considerando la ley de control de (7), con Δ en (8) como una función de

estado dependiente $\Delta(x(k))$.

Definimos la matriz $P(k)$ para todo tiempo k como:

$$P(k) = p(k)P' \quad (9)$$

donde $P' = P'^T > 0$ es una matriz constante dada y $p(k)$ es un parámetro escalar que será ajustado por el algoritmo GV. Así la ley de control queda como:

$$u(k) = -\frac{p(k)}{2}(R(x(k)) + \frac{p(k)}{2}P_1^*)^{-1}P_2^* \quad (10)$$

donde

$$P_1^* = g^T(x(k))P'g(x(k)) \quad , \quad P_2^* = g^T(x(k))P'f(x(k))$$

El algoritmo GV es entonces reformulado para el problema del control óptimo inverso .

Definición 2: (Función objetivo del GV)

Consideremos un parámetro variante en el tiempo $p(k) \in \mathcal{P} \subset \mathbb{R}^+$ con $p(k) > 0$ para todo k , y \mathcal{P} es un conjunto de valores admisibles para $p(k)$ (F. O. Tellez, 2011). Una función no negativa $Q : \mathbb{R}^n \times \mathbb{R} \rightarrow \mathbb{R}$ de la forma

$$Q(x(k), p(k)) = V_{GV}(x(k+1)) \quad (11)$$

donde $V_{GV}(x(k+1)) = -\frac{1}{2}x^T(k+1)P'x(k+1)$ y con $x(k+1)$ como se define en (1), es referido como la función objetivo de GV para el sistema (1). Definimos $Q(k(p)) := Q(x(k), p(k))$.

Definición 3: (Objetivo de control GV)

Consideramos una constante $p^* \in \mathcal{P}$. El objetivo de control GV para el sistema (1) con (10) es definido encontrando $p(k)$ de modo que la función objetivo de GV $Q(k(p))$ (F. O. Tellez, 2011), como en (11), satisfice:

$$Q(k(p)) \leq \Delta(x(k)) \quad , \quad \text{para } k \geq k^* \quad (12)$$

donde

$$\Delta(x(k)) = V_{GV}(x(k)) - \frac{1}{p(k)}u^T(k)R(x(k))u(k) \quad (13)$$

con $V_{GV}(x(k)) = -\frac{1}{2}x^T(k)P'x(k)$ y $u(k)$ como se define en (10); $k^* \in \mathbb{Z}^+$ es el tiempo al cual el objetivo de control GV es alcanzado.

Observación 1: La solución $p(k)$ debe garantizar que $V_{GV}(x(k)) > \frac{1}{p(k)}u^T(k)R(x(k))u(k)$ para obtener una función definida positiva $\Delta(x(k))$.

Para concluir, el algoritmo GV es utilizado para calcular $p(k)$ para alcanzar el objetivo de control GV definido anteriormente.

Proposición 1: Considere un sistema discreto no lineal de la forma (1) con (10) como entrada. Sea Q función objetivo GV definida en (2), y denotada $Q(k(p))$. Sea \bar{p} , $p^* \in \mathcal{P}$ valores constantes positivos y $\Delta(x(k))$ una función definida positiva con $\Delta(0) = 0$ y ϵ^* una constante positiva suficientemente pequeña. Asumimos que:

- Existe p^* y ϵ^* tal que

$$Q(k(p^*)) \leq \epsilon^* \ll \Delta(x(k))$$

y

$$1 - \epsilon^* / \Delta(x(k)) \approx 1 \quad (14)$$

■ Para $p(k) \in \mathcal{P}$:

$$(p^* - P(k))^T \nabla(p) Q(k(p)) \leq \epsilon^* - \Delta(x(k)) < 0 \quad (15)$$

donde $\nabla(p) Q(k(p))$ denota el gradiente de $Q(k(p))$ con respecto a $p(k)$.

Entonces, para cualquier condición inicial $p(0) > 0$, existe una $k^* \in \mathbb{Z}^+$ tal que la meta de control (8) es alcanzada por medio de la siguiente dinámica de variación del parámetro $p(k)$:

$$p(k+1) = p(k) - \gamma_{d(k)} \nabla(p) Q(k(p)) \quad (16)$$

con

$$\gamma_{d(k)} = \gamma_c \delta(k) |\nabla(p) Q(k(p))|^{-2}$$

$$0 < \gamma_c \leq 2 \Delta(x(k))$$

y

$$\delta(k) = \begin{cases} 1 & \text{para } Q(p(k)) > \Delta(x(k)) \\ 0 & \text{De otro modo} \end{cases} \quad (17)$$

Finalmente, para $k \geq k^*$, $p(k)$ se convierte en un valor constante denotado como \bar{p} y el algoritmo GV es completado.

Observación 2: Con $Q(x(k), p(k))$ como se definió en (11), la variación dinámica del parámetro $p(k)$ en (16) resulta en

$$p(k+1) = p(k) + \mathcal{P}^* \quad (18)$$

donde

$$\mathcal{P}^* = 8\gamma_{d(k)} \frac{f^T(x(k)) P' g(x(k)) R(x(k))^2 g^T(x(k)) f(x(k))}{(2R(x(k)) + p(k) g^T(x(k)) P' g(x(k)))^3} \quad (19)$$

el cual es positivo para todo tiempo k si $p(0) > 0$. Entonces la positividad para $p(k)$ esta asegurada y el requisito de $P(k) = P^T(k) > 0$ para $V(x(k)) = \frac{1}{2} x^T(k) P(k) x(k)$ con $P(k) = P^T(k) > 0$ es garantizado. Cuando el objetivo de control (12) es alcanzado, entonces $p(k) = \bar{p}$ para $k \geq k^*$. Esto es, la matriz $P(k)$ en (10) es considerada constante y $P(k) = P$ donde P es calculada como $P = \bar{p} P'$, con P' como una matriz de diseño definida positiva. Bajo estas circunstancias, se obtiene

$$\begin{aligned} \alpha(x(k)) &:= u(k) \\ &= -\frac{1}{2} (R(x(k)) + P_2(x(k)))^{-1} P_1(x(k)) \end{aligned} \quad (20)$$

donde $P_1(x(k)) = g^T(x(k)) P f(x(k))$ y $P_2(x(k)) = \frac{1}{2} g^T(x(k)) P g(x(k))$.

C. Seguimiento de referencia

Para el caso de seguimiento de referencia tenemos (F. O. Tellez, 2011):

$$u(k) = -\frac{1}{2} (R(x(k)) + P_2(x(k)))^{-1} P_1(x(k)) \quad (21)$$

donde $P_1(x(k)) = g^T(x(k)) P f(x(k) - x_{ref}(k+1))$ y $P_2(x(k)) = \frac{1}{2} g^T(x(k)) P g(x(k))$.

III. CONTROL DEL SISTEMA MULTI-MÁQUINA DE POTENCIA

D. Modelo completo de sistema multi-máquina de potencia

El modelo del sistema multi-máquina consiste en 3 generadores síncronos interconectados con 9 buses, para esto se modelan de manera independiente cada uno de los generadores síncronos, las ecuaciones diferenciales y algebraicas que representan la dinámica del i -ésimo generador y las restricciones en el flujo de potencia (V. H. Benítez Baltazar, 2010), (P. M. Anderson and A. A. Fouad, 1994), están dadas por:

$$\begin{aligned} \dot{x}_{1i} &= x_{2i} - \omega_s \\ \dot{x}_{2i} &= \left(\frac{\omega_s}{2H_i}\right) (T_{mi} - (\psi_{di} I_{qi} - \psi_{qi} I_{di})) \\ \dot{x}_{3i} &= \left(\frac{1}{T'_{doi}}\right) (-x_{3i} - X_{dd}) [I_{di} - X_{di}^* (x_{5i} + X_{dls})] + E_{fdi} \\ \dot{x}_{4i} &= \left(\frac{1}{T'_{qoi}}\right) (-x_{4i} - X_{qq}) [I_{qi} - X_{qi}^* (x_{6i} + X_{qls})] + E'_{di} \\ \dot{x}_{5i} &= \left(\frac{1}{T''_{doi}}\right) (-x_{5i} + x_{3i} - (X'_{di} - X_{lsi}) I_{di}) \\ \dot{x}_{6i} &= \left(\frac{1}{T''_{qoi}}\right) (-x_{6i} - x_{4i} - (X'_{qi} - X_{lsi}) I_{qi}) \end{aligned} \quad (22)$$

donde

$$X_{di}^* = \frac{X'_{di} - X''_{di}}{(X'_{di} - X_{lsi})^2}, \quad X_{qi}^* = \frac{X'_{qi} - X''_{qi}}{(X'_{qi} - X_{lsi})^2}$$

$$\begin{aligned} X_{dd} &= X_{di} - X'_{di}, & X_{qq} &= X_{qi} - X'_{qi} \\ X_{dls} &= (X'_{di} - X_{lsi}) I_{di}, & X_{qls} &= (X'_{qi} - X_{lsi}) I_{qi} \end{aligned}$$

que corresponden a parámetros de cada generador síncrono. La descripción de los estados se muestra a continuación:

- x_{1i} - ángulo de potencia del i -ésimo generador (rad)
- x_{2i} - velocidad rotacional del i -ésimo generador (rad/s)
- x_{3i} - voltaje interno del eje q del i -ésimo generador (p.u)
- x_{4i} - voltaje interno del eje d del i -ésimo generador (p.u)
- x_{5i} - flujo de enlace eje $1d$ del i -ésimo generador (p.u)
- x_{6i} - flujo de enlace eje $2q$ del i -ésimo generador (p.u)

Para los flujos de enlace del sistema se tiene lo siguiente

$$\begin{aligned} \psi_{di} &= -X''_{di} I_{di} + \frac{X''_{di} - X'_{lsi}}{X'_{di} - X_{lsi}} x_{3i} + \frac{X'_{di} - X''_{di}}{X'_{di} - X_{lsi}} x_{5i} \\ \psi_{qi} &= -X''_{qi} I_{qi} - \frac{X''_{di} - X'_{lsi}}{X'_{qi} - X_{lsi}} x_{4i} + \frac{X'_{qi} - X''_{qi}}{X'_{qi} - X_{lsi}} x_{6i} \end{aligned}$$

$$\begin{aligned}
0 &= P_i - V_i \sum_{j=1}^n V_j Y_{ij} \cos(\theta_i - \theta_j - \phi_{ij}) \\
0 &= Q_i - V_i \sum_{j=1}^n V_j Y_{ij} \sin(\theta_i - \theta_j - \phi_{ij})
\end{aligned} \tag{24}$$

donde ψ_{di} y ψ_{qi} son los flujos de enlace de los ejes d y q respectivamente del i -ésimo generador. P_i y Q_i son la potencia activa y reactiva en el bus i ($p.u.$), $V_i \angle \theta_i$ es el voltaje en el bus i , además $Y_i \angle \phi_{ij}$ es la admitancia entre el bus i y j .

E. Modelo reducido de sistema multi-máquina de potencia

El modelo anterior (V. H. Benítez Baltazar, 2010) esta en tiempo continuo, por lo cual se procede a discretizar los estados mediante un retenedor de orden cero, con los estados discretizados procedemos a implementar el modelo neuronal de orden reducido (A. Y. Alanis, E. N. Sánchez and F. O., 2011) como se muestra a continuación:

$$\begin{aligned}
\hat{x}_1(k+1) &= w_{11}(k)S(\hat{x}_1(k)) + w_{12}(k)S(\hat{x}_2(k)) \\
\hat{x}_2(k+1) &= w_{21}(k)S(\hat{x}_1(k))^6 + w_{22}(k)S(\hat{x}_2(k)) \\
&\quad + w_{23}(k)S(\hat{x}_3(k)) \\
\hat{x}_3(k+1) &= w_{31}(k)S(\hat{x}_1(k)) + w_{32}(k)S(\hat{x}_2(k)) \\
&\quad + w_{33}(k)S(\hat{x}_3(k)) + w_{34}u(k)
\end{aligned} \tag{25}$$

donde \hat{x}_i realiza la estimación de los estados x_i ($i = 1, 2, 3$).

El entrenamiento de la red es en línea, utilizando la configuración en paralelo mediante el filtro de Kalman extendido, el cual esta descrito por el siguiente algoritmo:

$$\begin{aligned}
K_i(k) &= \rho_i(k)H_i(k)M_i^{-1}(k) \\
\omega_i(k+1) &= \omega_i(k) + \eta_i K_i(k)e_i(k) \\
\rho_i(k+1) &= \rho_i(k) - K_i(k)H_i^T(k)\rho_i(k) + \phi_i(k)
\end{aligned} \tag{26}$$

con

$$\begin{aligned}
M_i(k) &= [\tau_i(k) + H_i^T(k)\rho_i(k)H_i(k)]^{-1} \\
e_i(k) &= x_i(k) - \hat{x}_i(k)
\end{aligned} \tag{27}$$

donde $\rho_i \in \mathbb{R}^{L_i \times L_i}$ es la matriz de covarianza asociada al error de predicción, $\omega_i \in \mathbb{R}^{L_i}$ es el vector de pesos, L_i es el número total de conexiones de alto orden de la red neuronal, $x_i \in \mathbb{R}$ es el i -ésimo componente de la planta, $\hat{x}_i \in \mathbb{R}$ es el i -ésimo componente de la red neuronal, η_i parámetro de diseño, $K_i \in \mathbb{R}^{L_i \times m}$ ganancia de la matriz de Kalman, $\phi_i \in \mathbb{R}^{L_i \times L_i}$ es la matriz de covarianza asociada al ruido en los estados, $\tau_i \in \mathbb{R}^{m \times m}$ es la matriz de covarianza asociada

al ruido en la medición, $H_i \in \mathbb{R}^{L_i \times m}$ matriz para la cual cada entrada (H_{ij}) es la derivada de una salida de la red neuronal, (\hat{x}_{ij}), con respecto (ω_{ij}), como se puede ver a continuación:

$$H_{ij}(k) = \left[\frac{\partial \hat{x}_i(k)}{\partial \omega_{ij}(k)} \right]_{\omega_i(k) = \hat{\omega}_i(k+1)} \tag{28}$$

$$i = 1, \dots, n \quad y \quad j = 1, \dots, L_i$$

Usualmente ρ_i , ϕ_i , τ_i , son inicializadas como matrices diagonales, con entradas $\rho_i(0)$, $\phi_i(0)$, $\tau_i(0)$, respectivamente.

Una vez que se tiene el modelo de orden reducido en el cual se aplicara la ley de control óptimo inverso GV de manera descentralizada para cada uno de los 3 generadores, se establece la ley de control a partir de (21) que queda como sigue:

$$u(k) = -\frac{1}{2}(R(x(k)) + P_2(x(k)))^{-1}P_1(x(k)) \tag{29}$$

donde $P_1(x(k)) = g^T(x(k))\hat{P}^*f(x(k) - x_{ref}(k+1))$ y $P_2(x(k)) = \frac{1}{2}g^T(x(k))\hat{P}^*g(x(k))$. De lo cual a partir de (25) $g(x(k))$, $f(x(k))$ y \hat{P}^* quedan como sigue:

$$g(x(k)) = \begin{bmatrix} 0 \\ 0 \\ \omega_{34} \end{bmatrix}$$

$$f(x(k)) = \begin{bmatrix} f_1(k) \\ f_2(k) \\ f_3(k) \end{bmatrix}$$

y

$$\begin{aligned}
f_1(k) &= w_{11}(k)S(\hat{x}_1(k)) + w_{12}(k)S(\hat{x}_2(k)) \\
f_2(k) &= w_{21}(k)S(\hat{x}_1(k))^6 + w_{22}(k)S(\hat{x}_2(k)) \\
&\quad + w_{23}(k)S(\hat{x}_3(k)) \\
f_3(k) &= w_{31}(k)S(\hat{x}_1(k)) + w_{32}(k)S(\hat{x}_2(k)) \\
&\quad + w_{33}(k)S(\hat{x}_3(k))
\end{aligned} \tag{30}$$

donde la matriz \hat{P}^* está dada por: $100*I$ para el generador 1, $5*I$ para el generador 2, $20*I$ para el generador 3, donde I es una matriz identidad de 3×3 .

IV. SIMULACIONES

El diagrama que se presenta en la figura (1) corresponde al sistema de 3 generadores interconectados, en cual se muestran la conexión que existe entre ellos y los parámetros correspondientes a las líneas de transmisión. Los datos para la simulación son tomados de (P. M. Anderson and A. A. Fouad, 1994) donde se describe la forma en la que es modelado el sistema y se dan los parámetros correspondientes a cada generador sincrónico.

En este trabajo se estabilizan los 18 estados correspondientes a los 3 generadores síncronos por medio del modelo reducido, logrando la estabilización del sistema, para realizar la simulación se utilizó un tiempo de muestreo de 0.005 ms.

La simulación del sistema consiste en introducir una falla trifásica al sistema, con duración de un tiempo de muestreo

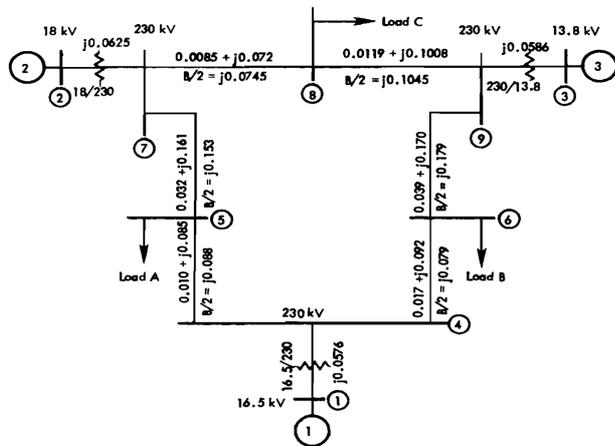


Figura 1. Sistema multi-máquina de potencia

(0.005 segundos), que ocurre cerca del bus 7 al final de la línea 5-7, esto ocurre a los 10 segundos de simulación, por lo cual podemos ver que el sistema tiene un estado pre-falla (tiempo menor a 10 segundos), un estado de falla (tiempo igual 10 segundos) y un estado pos-falla (tiempo mayor a 10 segundos). En el sistema las admitancias para las cargas están dadas en pu como:

Carga	Admitancia
A	$\bar{y}_{L5} = 1.2610 - j0.5044$
B	$\bar{y}_{L6} = 0.8777 - j0.2926$
C	$\bar{y}_{L8} = 0.9690 - j0.3391$

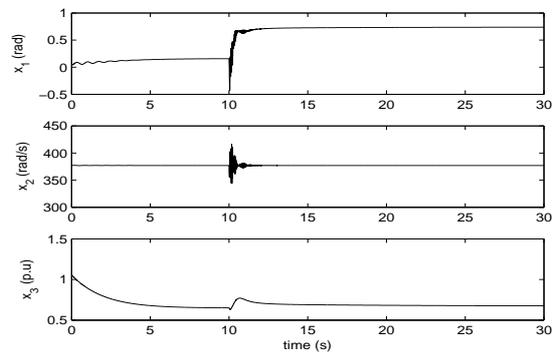
Las condiciones iniciales para el sistema son las siguientes:

Condiciones Iniciales	Generador 1	Generador 2	Generador 3
x_{01}	0.0396	0.3444	0.23
x_{02}	377	377	377
x_{03}	1.056	1.0502	1.0170
x_{04}	0	0.622	0.624
x_{05}	1.0478	0.7007	0.7078
x_{06}	-0.0425	-0.7568	-0.7328

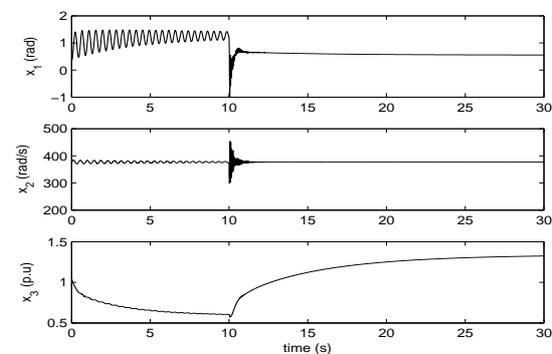
Dada la complejidad del sistema, lo que se hace es buscar que se establezca cerca de una región de operación en el cual este permanezca estable, las referencias para cada uno de los estados del modelo neuronal reducido correspondientes al sistema multi-máquina de potencia son consideradas a partir de las condiciones iniciales del sistema, intentando que las variables de estado regresen a su estado estable. Las cuales se muestran a continuación:

Referencias	Generador 1	Generador 2	Generador 3
x_{1ref}	0.0396	0.3444	0.23
x_{2ref}	377	377	377
x_{3ref}	.5	1.0502	1.0170

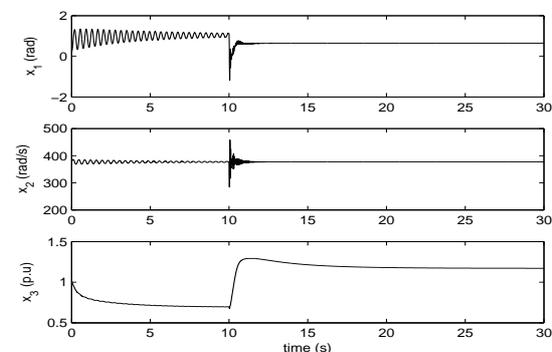
En la figura (2) se muestran los resultados de la estabilización de los estados correspondientes a los 3 generadores síncronos. Para cada generador x_1 corresponde a la posición, x_2 a la velocidad, x_3 al voltaje en el eje de cuadratura y a todo lo anterior resultado de la estabilización de los



(a) Generador 1



(b) Generador 2



(c) Generador 3

Figura 2. Simulación de sistema con falla a los 10 segundos

estados de los modelos neuronales reducidos que forman el sistema multi-máquina de potencia.

V. CONCLUSIONES

En este trabajo se ha validado el modelo en continuo del sistema multi-máquina de potencia que consta de tres generadores síncronos de orden completo interconectados y realizado la discretización de dicho sistema para posteriormente implementar una red neuronal con la cual se elabora una ley de control neuronal óptimo inversa con gradiente de velocidad GV para la estabilización del sistema ante una falla en una línea de transmisión. De la figura (2) se puede ver que el controlador propuesto

permite estabilizar los estados del sistema de manera eficiente, permitiendo al sistema recuperarse después de una falla. Si bien el sistema no sigue la referencia que se muestra en la tabla, lo que se intenta hacer es que este regrese a un estado estable después de la falla, dicho estado post-falla se considera dentro de los márgenes en el que el modelo del sistema utilizado se encuentra estabilizado ante la falla ocurrida.

VI. AGRADECIMIENTOS

Se agradece al CONACYT por la beca otorgada para los estudios de maestría, la cual permite la elaboración de este trabajo y al CINVESTAV unidad Guadalajara por el apoyo brindado ante la realización del mismo. Los autores también agradecen el apoyo del CONACYT mediante los proyectos 131678Y y 103191Y

REFERENCIAS

- A. L. Fradkov and A. Y. Pogromsky. *Introduction to Control of Oscillations and Chaos*. Singapore: World Scientific Publishing Co., 1998.
- A. S. Poznyak, E. N. Sanchez and W. Yu (2001). *Differential Neural Networks for Robust Nonlinear Control* World Scientific, Singapore, 2001.
- A. Y. Alanis, E. N. Sanchez and A. G. Loukianov (2007). *Discrete time adaptive backstepping nonlinear control via high order neural networks*. IEEE Transactions on Neural Networks, vol. 18, no. 4, pp. 1185-1195, July, 2007.
- A. Y. Alanis¹, E. N. Sánchez² and F. Ornelas² *Discrete-Time Inverse Optimal Neural Control for Synchronous Generators*. ¹CUCEI, Universidad de Guadalajara, ²CINVESTAV, Unidad Guadalajara
- C. Leunga, and L. Chan (2003). *Dual extended Kalman filtering in recurrent neural networks*. Neural Networks, vol 16, pp. 223-239, 2003.G.
- F. O. Tellez (2011). *Inverse Optimal Control for Discrete-Time Nonlinear Systems*. Tesis de doctorado, Cinvestav, Unidad Guadalajara, 2011.
- L. A. Feldkamp, T. M. Feldkamp, and D. V. Prokhorov (2001). *Neural network training with the nprKF*. Proceedings of International Joint Conference on Neural Networks. 01, 109-114, 2001.
- L. S. Pontryagin, V. G. Boltyanskii, R. V. Gamkrelidze, and E. F. Mishchenko. (1962) *The Mathematical Theory of Optimal Processes* New York, NY, USA: Interscience Publishers, Inc., 1962
- P. M. Anderson and A. A. Fouad. *Power System Control and Stability* IEEE Press., New York, USA, 1994.
- R. A. Freeman and P. V. Kokotovic. *Robust Nonlinear Control Design: State-Space and Lyapunov Techniques*. Cambridge, MA, USA: Birkhauser Boston Inc., 1996.
- R. E. Bellman. (1957) *Dynamic Programming* Princeton, NJ, USA: Princeton University Press, June 1957.
- R. E. Bellman and S. E. Dreyfus. (1962) *Applied Dynamic Programming* Princeton, NJ, USA: Princeton University Press, 1962.
- R. Grover and P. Y. C. Hwang (1992). *Introduction to Random Signals and Applied Kalman Filtering*. 2nd ed., John Wiley and Sons, New York, USA, 1992.
- R. J. Williams and D. Zipser (1989). *A learning algorithm for continually running fully recurrent neural networks*. Neural Computation, vol 1, pp 270-280, 1989.
- M. A. Arjona, R. Escarela-Perez, G. Espinosa-Perez, J. Alvarez-Ramirez. *Validity testing of third-order nonlinear models for synchronous generators*. Electric Power Systems Research vol.79 pp. 953-958, 2009
- M. Krsti and H. Deng. *Stabilization of Nonlinear Uncertain Systems*. Berlin, Germany: Springer-Verlag, 1998.
- V. H. Benítez Baltazar (2010). *Decentralized continuous time neural control*. Tesis de doctorado, Cinvestav, Unidad Guadalajara, 2010.
- Y. Song and J. W. Grizzle (1995). *The extended Kalman Filter as Local Asymptotic Observer for Discrete-Time Nonlinear Systems* Journal of Mathematical systems, Estimation and Control, vol. 5, no. 1, pp. 59-78, Birkhauser-Boston, 1995