

CT-773-SSI
Don. - 2014



Centro de Investigación y de Estudios Avanzados
del Instituto Politécnico Nacional
Unidad Guadalajara

Control Optimo Inverso en Tiempo Real para Generador Sincrono

**CINVESTAV
IPN
ADQUISICION
LIBROS**

Tesis que presenta:
José Roberto Robles Rodríguez

para obtener el grado de:
Maestro en Ciencias

en la especialidad de:
Ingeniería Eléctrica

Director de Tesis
Dr. Edgar Nelson Sánchez Camperos

CLASIF..	CT00677
ADQUIS..	CT-773-SSI
FECHA:	24-06-2014
PROCED..	Don-2014
	\$

XX (213871 2)

Control Optimo Inverso en Tiempo Real para Generador Sincrono

**Tesis de Maestría en Ciencias
Ingeniería Eléctrica**

Por:

José Roberto Robles Rodríguez

Ingeniero en Electrónica y Comunicaciones

Instituto Tecnológico y de Estudios Superiores de Monterrey
1982-1986

Director de Tesis

Dr. Edgar Nelson Sánchez Camperos

CINVESTAV del IPN Unidad Guadalajara, Septiembre de 2013.

CONTENIDO

Introducción.....	1
1.1 Motivación.....	1
1.2 Antecedentes.....	1
1.3 Objetivos.....	1
2 Fundamentos.....	3
2.1 Control Optimo.....	3
2.2 Estabilidad de Lyapunov.....	7
2.3 Análisis de Estabilidad Robusta.....	9
2.4 Identificación Neuronal.....	14
2.4.1 Sistema No Lineal.....	14
2.4.2 Red Neuronal de Alto Orden de Tiempo Discreto Recurrente.....	14
3 Control Optimo Inverso.....	19
3.1 Control Óptimo Inverso. Enfoque CLF.....	19
3.2 Algoritmo de Gradiente De Velocidad para el Control Optimo Inverso.....	21
3.2.1 Algoritmo de Gradiente de Velocidad.....	21
4 Implementación en tiempo real	25
4.1 Estimación de los Estados del Sistema.....	25
4.2 Características del Generador e Interface de Excitación.....	30
4.3 Programa de control en Labview y resultados obtenidos.....	30
5 Conclusiones y Trabajo a Futuro.....	36
5.1 Conclusiones.....	36
5.2 Trabajo Futuro.....	37
Referencias.....	38

Índice de Figuras

2.1 Solución del sistema de trayectorias con la propiedad ISS.....	9
4.1 Esquema de Control.....	26
4.2 Graficas de las tres señales de variables del estado.....	29
4.3 Graficas de señales voltaje de excitación y costo funcional.....	29
4.4 Etapas de adquisición y tratamientos de señales de entrada del programa.....	30
4.5 Etapa de control en “Labview”.....	31
4.6 Etapa de salida y despliegue en “Labview”.....	31
4.7 Etapa de salida y despliegue en “Labview”.....	32
4.8 Panel Frontal o de Instrumentos.....	32
4.9 Continuación Panel Frontal o de Instrumentos.....	33
4.10 Respuesta del generador.....	33
4.11 Respuesta de la frecuencia o velocidad de la maquina	34
4.12 Respuesta de la Fase del rotor.....	34
4.13 Salida del controlador frente a perturbaciones en la carga.....	35

Glosario de Términos y Acrónimos

Simbología

\forall	para toda
\in	pertenece a
\rightarrow	implica
\subset	contenido en
\cup	unión
\cap	intersección
$:=$	igual por definición
$\lambda \min(Q)$	el mínimo valor propio de la matriz Q
$\lambda \max(Q)$	el máximo valor propio de la matriz Q
$P > 0$	una matriz definida positiva P
$P \geq 0$	una matriz semidefinida positiva P
A	establecer o espacio vectorial
K	denota una función de clase K
K_∞	denota una función de clase K_∞
KL	denota una función de clase KL
\mathbb{N}	el conjunto de todos los números naturales
\mathbb{Z}^+	el conjunto de todos los enteros no negativos
\mathbb{R}	el conjunto de todos los números reales
\mathbb{R}^+	el conjunto de todos números reales positivos
$\mathbb{R}_{\geq 0}$	el conjunto de todos los números reales no negativos
\mathbb{R}^n	espacio vectorial de dimensión- n
$(\cdot)^T$	denota transposición
$(\cdot)^{-1}$	denota inversión

$(\cdot)^*$	denota una función óptima
C^ℓ	denota una función diferenciable continua de ℓ tiempos
$\ x\ _n$	la norma n del vector x
$\ x\ $	la norma Euclidiana del vector x
$a_1 \circ a_2$	la composición de dos funciones, donde $a_1(\cdot) \circ a_2(\cdot) = a_1(a_2(\cdot))$

Acrónimos

BIBS	Entrada-Acotada Estado-Acotado
CLF	Función de Control de Lyapunov
CT	Tiempo-Continuo
DOF	Grados de Libertad
DT	Tiempo-Discreto
EKF	Filtro Extendido de Kalman
GS	Globalmente Estable
GAS	Asintóticamente Globalmente Estable
HJB	Hamilton-Jacobi-Bellman
HJI	Hamilton-Jacobi-Isaacs
ISS	Entrada a Estado Estable
MI	Matriz de Desigualdad
LTI	Invariante de Tiempo Lineal
PBC	Control basado en pasividad
RHONN	Red Neuronal Recurrente de Alto Orden
RNN	Red Neuronal Recurrente
RCLF	Función Lyapunov de Control Robusto
SG	Gradiente de Velocidad

Resumen

En este trabajo se presenta un sistema de control óptimo inverso discreto con estimador neuronal de orden superior en tiempo real, implementado con una computadora personal, interfaces de adquisiciones de datos via "usb", "driver" de excitación con "PWM", software de visualización y control Labview de National Instruments.

El generador utiliza una maquina pequeña, del tipo automotriz con 12 Volts nominales a 60 amps máximo, 12 polos, para entregar una frecuencia aproximada a los 176 Hz, al ser impulsada por un motor de inducción monofásico de $\frac{3}{4}$ HP a 1760 RPM.

En la primera parte se presentan los fundamentos teórico que sustenta este proyecto, posteriormente se detalla el algoritmo de control y red neuronal utilizado, se muestra el programa y detallas de la interfaces gráficas, para finalmente mostrar y analizar los resultados obtenidos de la respuesta del sistema ante perturbaciones tipo escalón en la carga.

Abstract

This dissertation presents a discrete inverse optimal control system with discrete high order neural estimator in real time, implemented with a personal computer, data acquisition interfaces via USB, PWM excitation driver and National Instrument Labview display and control software

The generator uses a small machine, the 12-volt- 60 amperes nominal maximum automotive type, to deliver an approximate frequency to 176 Hz, to be driven by a $\frac{3}{4}$ HP/1760RPM single phase induction motor

Initially it presents the fundamentals of development behind this project, then details the control algorithm and neural network used, shows the program and details of the GUI, to finally display and analyze the results of the system's response to disturbances in the load step type.

Capítulo 1

Introducción

1.1 Motivación y Antecedentes

Debido a los trabajos realizados sobre los generadores síncronos [1,4, 5], en esta tesis se expone el diseño y la implementación de un sistema de control óptimo inverso en tiempo real de un generador síncrono. Se acopló directamente un motor de inducción monofásico a un generador síncrono trifásico, conectado este último, de manera independiente (no a un bus) a una carga trifásica resistiva. Se contempla la estimación del sistema utilizando una red neuronal de alto orden (RHONN por sus siglas en inglés) entrenada mediante el filtro de Kalman, para posteriormente implementar una ley de control óptimo inverso para la estabilización de las variables de estado, y el seguimiento de trayectoria. Las variables de estado consideradas son: Angulo de Potencia(o rotor); Frecuencia y Voltaje en terminales de la maquina. Se realiza el control mediante una computadora personal, una interface de adquisición de datos, y el software de visualización y control “Labview” de National Instruments. Se analiza el comportamiento ante perturbaciones de tipo escalón en la carga.

1.2 Objetivos

Los Objetivos de este trabajo de tesis son:

- Proponer una red neuronal de orden superior para la estimación de los estados de la máquina.
- Desarrollo de un programa de computadora para la implementación en tiempo real de un controlador óptimo inverso mediante la estimación con red neuronal.
- Desarrollo de pruebas y análisis del comportamiento en tiempo real ante perturbaciones en la carga.

1.3 Estructura de la tesis

La tesis se ordena de la siguiente forma:

En el capítulo 2, se dan los preliminares matemáticos para la comprensión de técnicas utilizadas en la estabilización de los estados.

El capítulo 3, trata los fundamentos del control óptimo inverso vía pasividad.

El capítulo 4, trata los fundamentos del control óptimo inverso a través de una función de control de Lyapunov (CLF por sus siglas en inglés).

En el capítulo 5, Se desarrolla el Controlador Optimo Inverso en Tiempo Real de Generador Síncrono y los resultados obtenidos.

Finalmente se presentan las conclusiones de los resultados obtenidos y el trabajo futuro.

Capítulo 2

Fundamentos

En este capítulo se describen brevemente los resultados útiles en la teoría de control óptimo, Estabilidad de Lyapunov, necesaria en los próximos capítulos, para la solución del problema de control óptimo inverso.

2.1 Control Óptimo

Esta sección está dedicada a una breve discusión de la metodología del control óptimo inverso y sus limitaciones.

Considere el sistema no lineal de tiempo discreto con entrada afín:

$$x(k+1) = f(x(k)) + g(x(k))u(k) \tag{2.1}$$

Donde $x_k \in \mathbb{R}^n$ es el estado del Sistema $u_k \in \mathbb{R}^m$ es la entrada de control, $f(x_k): \mathbb{R}^n \rightarrow \mathbb{R}^n$ y $g(x_k): \mathbb{R}^n \rightarrow \mathbb{R}^{n \times m}$ son mapas discretos, $k \in \mathbb{Z}^+ = \{0,1,2, \dots\}$. Consideramos que X es un punto de equilibrio aislado de $f(x) + g(x)\bar{u}$ con la constante \bar{u} , esto es, $f(f(\bar{x}) + g(\bar{x})\bar{u}) = \bar{x}$ Sin pérdida de generalidad, consideramos $\bar{x} = 0$ para una constante \bar{u} , $f(0) = 0$ y el $\text{rango}\{g(x_k)\} = m \forall x_k \neq 0$

A partir de ahora se puede escribir el sistema (2.1) como

$$x_{k+1} = f(x_k) + g(x_k)u_k \quad x_0 = x(0) \tag{2.2}$$

El subíndice $k \in \mathbb{Z}^+$ se mantendrá para el valor de las funciones y/o variables en el momento k .

La siguiente función de coste significativa está asociada con el sistema (2.2)

$$J(x_k) = \sum_{n=k}^{\infty} (l(x_n) + u_n^T R(x_n) u_n) \quad (2.3)$$

Donde $J(x_k): \mathbb{R}^n \rightarrow \mathbb{R}^+$; $l(x_k): \mathbb{R}^n \rightarrow \mathbb{R}^+$ es una función semidefinida positiva y $R(x_k): \mathbb{R} \rightarrow \mathbb{R}^{m \times m}$ es una matriz de ponderación definida positiva simétrica real.

La función de coste significativa (2.3) es una medida del rendimiento [52]. Las entradas de $R(x_k)$ pueden ser funciones del estado del sistema con el fin de variar la ponderación en los esfuerzos de control de acuerdo al estado del valor [52]. Teniendo en cuenta el enfoque de diseño de control de realimentación del estado, definimos que el estado completo x_k es disponible.

La ecuación (2.3) puede ser reescrita de la siguiente manera

$$\begin{aligned} J(x_k) &= l(x_k) + u_k^T R(x_k) u_k + \sum_{n=k}^{\infty} (l(x_n) + u_n^T R(x_n) u_n) \\ &= l(x_k) + u_k^T R(x_k) u_k + J(x_{k+1}) \end{aligned} \quad (2.4)$$

Donde necesitamos la condición del límite $J(0) = 0$ de modo que $J(x_k)$ se convierte en una Función De Lyapunov [4,53]. Si el valor de $J(x_k)$ es finito, entonces es una función del estado inicial x_0 .

Cuando $J(x_k)$ está en su mínimo valor, el cual se define como $J^*(x_k)$, es llamado *Función de valor optimo*, y será usada como una función de Lyapunov, es decir $J^*(x_k) \triangleq V(x_k)$.

Del principio de Optimización de Bellman [54,55] se sabe que para el caso de la optimización de horizonte infinito, el valor de la función $V(x_k)$ se convierte en una invariante en el tiempo y satisface la ecuación de tiempo discreto de Bellman. [53,55,56]

$$V(x_k) = \min_{u_k} \{ l(x_k) + u_k^T R(x_k) u_k + V(x_{k+1}) \} \quad (2.5)$$

Donde $V(x_{k+1})$ depende tanto de x_k y u_k por medio de $x_k + 1$ en (2.2). Tenga en cuenta que la ecuación de tiempo discreto de Bellman se resuelve hacia atrás en el tiempo [53]

Con el fin de establecer las condiciones que la ley de control óptimo debe cumplir, definimos la Hamiltoniana Discreta en el tiempo como

$$H(x_k, u_k) = l(x_k) + u_k^T R(x_k) u_k + V(x_{k+1}) - V(x_k) \quad (2.6)$$

Una condición necesaria de la ley de control óptimo u_k que debe satisfacer es $\frac{\partial H(x_k, u_k)}{\partial u_k} = 0$

[52] lo cual es equivalente a calcular el gradiente de (2.5) lado derecho con respecto a u_k , de esta manera:

$$\begin{aligned} 0 &= 2R(x_k)u_k + \frac{\partial V(x_{k+1})}{\partial u_k} \\ &= 2R(x_k)u_k + g^T(x_k) \frac{\partial V(x_{k+1})}{\partial x_{k+1}} \end{aligned} \quad (2.7)$$

por lo tanto, la ley de control óptimo se formula como:

$$u^* = -\frac{1}{2} R^{-1}(x_k) g^T(x_k) \frac{\partial V(x_{k+1})}{\partial x_{k+1}} \quad (2.8)$$

Con la condición de límite $V(0) = 0$; u_k^* es usado cuando queremos enfatizar que u_k es óptimo.

Por otra parte si, $H(x_k, u_k)$ tiene una forma cuadrática en u_k y $R(x_k) > 0$, entonces

$$\frac{\partial^2 H(x_k, u_k)}{\partial^2} > 0$$

Mantiene como condición suficiente para que la ley de control óptimo (2.8) (globalmente [52]) minimiza $H(x_k, u_k)$ y el índice de rendimiento (2.3) [54]

Sustituyendo (2.8) en (2.5) obtenemos la ecuación de tiempo discreto Bellman-Jacobbi-Hammilton (HJB), descrita por

$$\begin{aligned}
 V(x_k) &= l(x_k) + \left(-\frac{1}{2} R^{-1}(x_k) g^T(x_k) \frac{\partial V(x_{k+1})}{\partial x_{k+1}}\right)^T \\
 &\quad \times R(x_k) \left(-\frac{1}{2} R^{-1}(x_k) g^T(x_k) \frac{\partial V(x_{k+1})}{\partial x_{k+1}}\right) + V(x_{k+1}) \\
 &= l(x_k) + V(x_{k+1}) + \frac{1}{4} \frac{\partial V^T(x_{k+1})}{\partial x_{k+1}} g(x_k) R^{-1}(x_k) g^T(x_k) \frac{\partial V(x_{k+1})}{\partial x_{k+1}}
 \end{aligned}
 \tag{2.9}$$

La cual puede ser reescrita de la siguiente manera:

$$l(x_k) + V(x_{k+1}) - V(x_k) + \frac{1}{4} \frac{\partial V(x_{k+1})}{\partial x_{k+1}} g(x_k) R^{-1}(x_k) g^T(x_k) \frac{\partial V(x_{k+1})}{\partial x_{k+1}} = 0
 \tag{2.10}$$

El problema de la solución de la ecuación diferencial parcial HJB no es sencillo. Esta es una de las principales desventajas del control óptimo en tiempo-discreto para sistemas no lineales.

Para superar este problema, se propone resolver el problema de control óptimo inverso.

2.2 Estabilidad en el sentido de Lyapunov

Recordemos los siguientes resultados.

Definición 2.1 (Función acotada radialmente [30]) Una función $V(x_k)$ que satisface la condición $V(x_k) \rightarrow \infty$ cuando $\|x_k\| \rightarrow \infty$ se dice que está acotada radialmente.

Teorema 2.1 (Estabilidad asintótica) El equilibrio $x_k=0$ de (2.2) es globalmente asintóticamente estable si existe una función $V: \mathbb{R}^n \rightarrow \mathbb{R}$ de tal manera que (i) V es una función definida positiva, acotada radialmente y (ii) $-\Delta V(x_k)$ es una función definida positiva donde $\Delta V(x_k) = V(x_{k+1}) - V(x_k)$.

Teorema 2.2 (Estabilidad Exponencial [59]). Suponga que existe una función definida positiva $V: \mathbb{R}^n \rightarrow \mathbb{R}$ y las constantes $c_1, c_2, c_3 > 0$ y $p > 1$ de tal manera que:

$$c_1 \|x\|^p \leq V(x_k) \leq c_2 \|x\|^p \quad (2.11)$$

$$\Delta V(x_k) \leq -c_3 \|x\|^p \quad \forall k \geq 0 \quad \forall x \in \mathbb{R}^n \quad (2.12)$$

Por lo tanto $x_k=0$ es un equilibrio estable exponencial para el sistema (2.2).

Claramente, la estabilidad exponencial implica estabilidad asintótica. Lo contrario es, sin embargo falso.

Debido al hecho de que el control óptimo inversa se basa en una función de Lyapunov, estableceremos la siguiente definición

Definición 2.1. Control de la función de Lyapunov [60,61] dejemos que $V(x_k)$ sea una función acotada radialmente, con $V(x_k) > 0, \forall x_k \neq 0$ y $V(0) = 0$. Si para cualquier $x_k \in \mathbb{R}^n$ existen valores reales u_k de tal manera que:

$$\Delta V(x_k, u_k) < 0$$

donde la diferencia de Lyapunov $\Delta V(x_k, u_k)$ está definida como $V(x_{k+1}) - V(x_k) = V(f(x_k) + g(x_k)u_k) - V(x_k)$.

De esta manera se dice que $V(\cdot)$ es una "función de control de Lyapunov tiempo-discreto" (FLC) para el sistema (2.2)

Suposición 2.1 Supongamos que $x = 0$ es un punto de equilibrio para (2.2) y que existe una función de control de Lyapunov $V(x_k)$ de tal manera que:

$$\alpha_1(\|x\|) \leq V(x_k) \leq \alpha_2(\|x_k\|) \tag{2.13}$$

$$\Delta V(x_k, u_k) < -\alpha_3(\|x_k\|) \tag{2.14}$$

donde α_1, α_2 y α_3 son funciones de clase K_∞ y $\|\cdot\|$ indica la usual norma euclidiana. Entonces, el origen del sistema es un punto de equilibrio asintóticamente estable mediante u_k como entrada

La existencia de este FLC está garantizada por un teorema inverso de la teoría de estabilidad de Lyapunov [62]

Como un caso especial el cálculo de funciones de clase K_∞ en (2.13) simplifica cuando toman la forma especial $\alpha_i(r) = k_i r^c, k_i > 0, c = 2$ e $i = 1, 2$.en particular para una función definida positiva cuadrática $V(x_k) = \frac{1}{2} x_k^T P x_k$ con una matriz definida positiva y simétrica P . en ese caso (2.3) resulta en

$$\lambda \min(P) \|x\|^2 \leq x_k^T P x_k \leq \lambda \max(P) \|x\|^2 \tag{2.15}$$

donde $\lambda \min(P)$ es el valor propio mínimo de la matriz P y $\lambda \max(P)$ es el valor propio máximo de la matriz P

2.3 Análisis de Estabilidad Robusta

En esta sección se revisan los resultados de la estabilidad de los sistemas no lineales perturbado, para los cuales las perturbaciones que no desaparecen son consideradas.

Ya no podemos estudiar la estabilidad del origen como un punto de equilibrio, ni debemos esperar que la solución del sistema perturbado se acerque al origen cuando $k \rightarrow \infty$.

Lo mejor que podemos esperar es que si la perturbación es pequeña, en cierto sentido, entonces la solución del sistema será en última instancia, limitada por un pequeño límite [30] Esto introduce el concepto de acotación final

Definición 2.3 (Acotación Final [30,63]). Las soluciones de (2.2) con $u_k = 0$ se dice que son uniformemente en última instancia limitado si existen las constantes positivas b y c y para cada $\alpha \in (0, c)$, hay una constante positiva $T = T(\alpha)$, de tal manera que:

$$\|x_0\| < \alpha \rightarrow \|x_k\| \leq b, \quad \forall k \geq k_0 + T \quad (2.16)$$

Donde k_0 es el instante inicial en el tiempo. Se dice que son globalmente uniforme en última instancia limitado si (2.16) vale para la variable arbitraria α , la constante b en (2.16) se conoce como el límite final.

La siguiente definición de estabilidad de entrada-estado (ICS) para las soluciones de sistema (2.2) serán utilizados para estudiar las propiedades de estabilidad de una clase de sistemas no lineales de tiempo discreto perturbados. Esta propiedad ISS intenta capturar la noción de límite-entrada limitada de estado (BIBS). Decimos que el sistema (2.2) es (BIBS) uniformemente estable, si los estados iniciales limitados y control producen trayectorias uniformemente limitadas [64]. La forma más sencilla de introducir la noción de sistema ISS es como una generalización de la estabilidad asintótica global (GAS) de la solución trivial $x_k = 0$ para (2.2) y [65]

Recordemos que la función $\gamma: \mathbb{R}_{\geq 0} \rightarrow \mathbb{R}_{\geq 0}$ es una *funcion - k* si es continua, estrictamente creciente y $\gamma(0) = 0$; es una *funcion - k_∞* si es una *funcion - k* y también $\gamma(s) \rightarrow \infty$ cuando




Figura 2.1: Solución del sistema de trayectorias con la propiedad ISS

$s \rightarrow \infty$ y es una función definida positiva si $\gamma(s) > 0$ para toda $s > 0$ y $\gamma(0) = 0$. Una función $\beta: \mathbb{R}_{\geq 0} \times \mathbb{R}_{\geq 0} \rightarrow \mathbb{R}_{\geq 0}$ es una *función -KL* para cada $t \geq 0$, la función $\beta(\cdot, t)$ es una *función -K* y para cada $s \geq 0$, la función $\beta(s, \cdot)$ se decrementa y $\beta(s, t) \rightarrow 0$ cuando $t \rightarrow \infty$ [64]. $\mathbb{R}_{\geq 0}$ se refiere a los números reales no negativos.

DEFINICION 2.1 (Propiedad ISS [64, [66]). El sistema (2.2) es (globalmente) estable de entrada a estado respecto a u_k si existe una *función -KL* β y una *función -k* γ de tal manera que para cada entrada $u \in l_{\infty}^m$ y cada $x_0 \in \mathbb{R}^n$ se cumple que la condición (2.2) satisface

$$\|x_k\| \leq \beta(\|x_0\|, k) + \gamma\left(\sup_{T \in [k_0, \infty)} \|u_T\|\right) \quad (2.17)$$

Donde $\sup_{T \in [k_0, \infty)} \{\|u_T\| : T \in \mathbb{Z}^+\} < \infty$, el cual está definido por $u \in l_{\infty}^m$

Así el sistema (2.2) se dice que es ISS si la propiedad (2.17) se satisface [67].

La interpretación de (2.17) es la siguiente: para un límite controlado u , la solución del sistema permanece en la esfera de radio $\beta(\|x_0\|, k) + \gamma(\sup_{T \in [k_0, \infty)} \|u_T\|)$. Además, a medida que k aumenta, todas las trayectorias se aproximan a la esfera de radio $\gamma(\sup_{T \in [k_0, \infty)} \|u_T\|)$ (es decir, todas las trayectorias serán limitadas en última instancia con el límite en última instancia γ). Debido a que γ es de la clase K , esta esfera es una pequeña porción del total cuando $\|u\|$ es pequeña.. Ver figura 2.1

Definición 2.5 (Propiedad de la ganancia asintótica). Se dice que el sistema (2.2) tiene ganancia asintótica $-K$ si existe alguna $\gamma \in K$, por lo tanto

$$\lim_{k \rightarrow \infty} \|x_k(x_0, u)\| \leq \lim_{k \rightarrow \infty} \gamma(\|u_k\|) \quad (2.18)$$

Para toda $x_0 \in \mathbb{R}^n$

Teorema 2.3 (Sistema ISS [64]). Considerando el sistema 2.2 los siguientes puntos son equivalentes:

- 1) Es ISS
- 2) ES BIBS y admite ganancia asintótica $-K$

Dejemos que ℓ_d sea la constante de lipschitz de tal manera que para toda β_1 y β_2 en algún territorio de (x_k, u_k) , la función de Lyapunov $V(x_k)$, satisface la condición ([68])

$$\|V(\beta_1) - V(\beta_2)\| \leq \ell_d \|(\beta_1) - (\beta_2)\|, \quad \ell_d > 0 \quad (2.19)$$

Definición 2.6 (Función ISS de Lyapunov [64]) Una función continua V en \mathbb{R}^n es llamada una Función ISS de Lyapunov para el sistema (2.2) si

$$\alpha_1(\|x_k\|) \leq V(x_k) \leq \alpha_2(\|x_k\|) \quad (2.20)$$

Valido para $\alpha_1, \alpha_2 \in K_\infty$ y:

$$V(f(x_k, u_k)) - V(x_k) \leq -\alpha_3(\|x_k\|) + \sigma(\|u_k\|) \quad (2.21)$$

Para $\alpha_3 \in K_\infty, \sigma \in K$. Una función de Lyapunov discreta es aquella que es discreta.

Note que si $V(x_k)$ es una función ISS DT de Lyapunov para (2.2), entonces $V(x_k)$ es una función DT de Lyapunov para el sistema de entrada $-0 \quad x_{k+1} = f(x_k) + g(x_k)0$.

Proposición 2.1. Si el sistema (2.2) admite una función ISS de Lyapunov, entonces es un ISS [64].

Ahora, consideremos el sistema perturbado:

$$x_{k+1} = f(x_k) + g(x_k)u_k + d_k, \quad x_0 = (0) \quad (2.22)$$

donde $x_k \in \mathbb{R}^n$ es el estado del sistema en el momento $k \in \mathbb{Z}^+$, $u_k \in \mathbb{R}^m$ es el control $d_k \in \mathbb{R}^n$, es el termino alterado, $f: \mathbb{R}^n \rightarrow \mathbb{R}^n$ y $g: \mathbb{R}^n \rightarrow \mathbb{R}^{n \times m}$ son asignaciones discretas, $f(0) = 0$. El termino alterado d_k podría resultar de errores de modelado, el envejecimiento, o incertidumbres y alteraciones que existen para cualquier problema real ([30])

Definición 2.7 (Función ISS-CLF) Una función definida positiva DISCRETA radialmente no acotada $V : \mathbb{R}^n \rightarrow \mathbb{R}$ se dice que es un ISS-CLF para el sistema (2.22) si existe una función p de clase K_∞ de forma que la siguiente implicación esta sujeta a $\forall x \neq 0$ y $\forall d \in \mathbb{R}^n$:

$$\alpha_1(\|x_k\|) \leq V(x_k) \leq \alpha_2(\|x_k\|) \quad (2.23)$$

valido para $\alpha_1, \alpha_2 \in K_\infty$ y

$$\|x_k\| \geq p(\|d_k\|) \rightarrow \inf_{u_k \in \mathbb{R}^n} \Delta V_d(x_k, d_k) < -\alpha_3(\|x_k\|) \quad (2.24)$$

donde:

$$\Delta V_d(x_k, d_k) := V(x_{k+1}) - V(x_k) \text{ y } \alpha_3(\|x_k\|)$$

Observación 2.1

La conexión entre la existencia de una función de Lyapunov y la entrada a la estabilidad de estado es aquella donde, una estimación de la función de ganancia γ en (2.17) es $\gamma = \alpha_1^{-1} \circ \alpha_2 \circ p$ donde \circ significa *composición* de funciones con α_1 y α_2 como se define en (2.23) [11]

Note que si $V(x_k)$ es una función de control de Lyapunov ISS para (2.2) entonces $V(x_k)$ es una función de control de Lyapunov para el sistema alterado -0 $x_{k+1} = f(x_k) + g(x_k)u_k$

Proposición 2.2 (Sistema ISS-CLF) Si el sistema (2.2) admite un ISS-CLF, entonces es un ISS.

2.3.1 Control Optimo para sistemas alterados

Para el sistema no lineal alterado-discreto (2.22), la ecuación de Bellman se convierte en la ecuación de Isaac descrita por:

$$V(x_k) = \min \{ l(x_k) + u_k^T R(x_k) u_k + V(x_k, u_k, d_k) \} \quad (2.25)$$

Y la ecuación Isaacs-Jacob-Hamiltoneano (HJI) asociada con el sistema (2.22) y costo funcional (2.3) es:

$$\begin{aligned}
0 &= \inf_u \sup_{d \in D} \{l(x_k) + u_k^T R(x_k) u_k + V(x_{k+1}) - V(x_k)\} \\
&= \inf_u \sup_{d \in D} \{l(x_k) + u_k^T R(x_k) u_k + V(x_k, u_k, d_k) - V(x_k)\}
\end{aligned}$$

(2.26)

Donde D es un conjunto de funciones limitadas localmente, y la función es $V(x_k)$ desconocida. Sin embargo, la búsqueda de una solución de la ecuación HJI (2.26) para $V(x_k)$ con (2.8) es el principal inconveniente del control óptimo robusto, esta solución puede no existir o puede ser muy difícil de resolver [17].

Note que $V(x_{k+1})$ en (2.26) es la función del termino alterado d_k .

2.4 Identificación Neuronal

El análisis de los sistemas no lineales de gran escala requiere de una gran cantidad de esfuerzo, ya que los parámetros son difíciles de obtener [43] Por lo tanto, para sintetizar un controlador basado en el modelo de la planta que se tienen incertidumbres no es práctico.

Para situaciones realistas, un control basado en un modelo de la planta no puede realizar como se desee, debido a las alteraciones internas y externas, parámetros inciertos, o dinámicas no modeladas [43]

Este hecho motiva la necesidad de derivar un modelo basado en una red neuronal recurrente de alto orden (RHONN), para identificar las dinámicas de la planta.

Se analizó una clase general de sistemas que son afín en el control con términos con alteraciones, tal como [70]: Se supone la misma estructura para la red neuronal.

2.4.1 Sistemas No Lineales

Considere una clase de sistema no lineal alterado de tiempo discreto:

$$x_{k+1} = \bar{f}(x_k) + \bar{g}(x_k)u_k \Gamma_k \quad (2.33)$$

Donde $x_k \in \mathbb{R}^n$ es el estado del sistema en el momento k , $\Gamma_k \in \mathbb{R}^n$ es un término de alteración desconocido y limitada que representa de errores de modelado y parámetros indefinidos y alterados, $\bar{f}: \mathbb{R}^n \rightarrow \mathbb{R}^n$ y $\bar{g}: \mathbb{R}^n \rightarrow \mathbb{R}^{n \times m}$ son mapas discretos. Sin pérdida de generalidad $x_k = 0$ es un punto de equilibrio para (2.33). Asumimos que $\bar{f}(0) = 0$ y $\text{rango}\{\bar{g}(x_k)\} = m \forall x_k \neq 0$.

2.4.2 Red Neuronal de Alto Nivel de tiempo discreto.

Para identificar el sistema (2.33) la siguiente RHONN de tiempo discreto propuesta en en [46]

$$x_{i,k+1} = w_i p_i(x_k, u_k)$$

Donde $x_k = [x_{1,k} \ x_{2,k} \ \dots \ x_{n,k}]^T$, x_i es el estado de la neurona i -th la cual identifica al componente del vector de estado x_k en (2.33), $i=1, \dots, n$; w_i es el vector de peso adaptado en línea respectivo y $u_k = [u_{1,k} \ u_{2,k} \ \dots \ u_{m,k}]$ es el vector de entrada de la red neuronal p_i es un vector dimensional L_p definido como:

$$\rho_i(x_k, u_k) = \begin{bmatrix} \rho_{i_1} \\ \rho_{i_2} \\ \vdots \\ \rho_{i_{L_p}} \end{bmatrix} = \begin{bmatrix} \prod_{\ell \in I_1} Z_{i_\ell}^{d_{i_\ell}(1)} \\ \prod_{\ell \in I_2} Z_{i_\ell}^{d_{i_\ell}(2)} \\ \vdots \\ \prod_{\ell \in I_{L_p}} Z_{i_\ell}^{d_{i_\ell}(L_p)} \end{bmatrix} \quad (2.35)$$

Donde d_{i_ℓ} son enteros no negativos L_p es el numero p de conexiones de alto nivel $\{I_1, I_2, \dots, I_{L_p}\}$ es una colección de subconjuntos no ordenados de $\{1, 2, \dots, n+m\}$

$$Z_i = \begin{bmatrix} Z_{i_1} \\ \vdots \\ Z_{i_n} \\ Z_{i_{n+1}} \\ \vdots \\ Z_{i_{n+m}} \end{bmatrix} = \begin{bmatrix} S(x_{1,k}) \\ \vdots \\ S(x_{n,k}) \\ u_{1,k} \\ \vdots \\ u_{m,k} \end{bmatrix}$$

donde la función de Sigmoid $S(\cdot)$ esta definida por

$$S(x) = \frac{\alpha_i}{1 + e^{-\beta_i x}} - \gamma_i$$

con $S(\cdot) \in [-\gamma_i, \alpha_i - \gamma_i]$; α_i, β_i y γ_i que son constantes positivas.

Se propone la siguiente modificación de la RHONN de tiempo discreto para el sistema descrito por (2.33)[71]

Las medidas neuronales relacionadas con con las entradas de control pueden ser ajustadas (w_i') para asegurar la controlabilidad del identificador.

Basado en esta modificación y usando la estructura del sistema (2.33), se propone el siguiente modelo de red neuronal

$$x_{i,k+1} = w_{i,k}^T p_i(x_k) + w_i'^T \psi_i(x_k, u_k) \quad (2.36)$$

Con el fin de identificar (2.33) donde x_i es el i-nesimo estado neuronal; $w_{i,k}$ es el vector de peso en línea ajustable y w_i' es el vector de peso regulado, ψ denota una función de x o de u Correspondientemente a la estructura de la planta (2.33) o a las salidas externas de la red, respectivamente. El Vector p_i en (2.36) es como (2.35) sin embargo Z_i es redefinido como

$$Z_i = \begin{bmatrix} Z_{i_1} \\ \vdots \\ Z_{i_n} \end{bmatrix} = \begin{bmatrix} S(x_{1,k}) \\ \vdots \\ S(x_{n,k}) \end{bmatrix}$$

El vector de peso en línea ajustable es definido como

$$w_{i,k} = \left[w_{i1,k} \dots w_{iL_p,k} \right]^T$$

Recordando 2.2. Vale la pena notar que (2.36) no considera el termino de alteración (Γ_k) debido a que los valores de la RHONN están ajustado en línea y por lo tanto la RHONN identifica las dinámicas del sistema no lineal, los cuales incluyen los efectos de alteración

Modelos de RHONN

De los resultados presentados en [44] podemos asumir que existe una RHONN que modela (2.33), con ello el modelo de planta (2.33) puede ser descrito por

$$X_{k+1} = W_k^* p(x_k) + W'^* \psi(x_k, u_k) + v_k \quad (2.37)$$

Donde $W_k^* = \left[w_{1k}^{*T} w_{2k}^{*T} \dots w_{nk}^{*T} \right]^T$ y $W'^* = \left[w_1'^{*T} w_2'^{*T} \dots w_n'^{*T} \right]^T$

Son las matrices de peso optimas desconocidas y el error de modelado v_k es dado por:

$$v_k = \bar{f}(x_k) + \bar{g}(x_k)u_k + \Gamma_k - W'' p(x_k) - W'' \varphi''(x_k, u_k).$$

El termino de modelado de error v_k se puede representar arbitrariamente pequeño seleccionando el numero apropiado L_p de conecciones de alto nivel[44]. Las matrices de peso ideal W_k^* y W'' son cantidades artificiales requeridas para propósitos analíticos. En general se asume que este vector existe, es constante pero desconocido. Los vectores optimos de peso $w_{i,k}^*$ serán aproximadas por los vectores de peso en línea ajustables $w_{i,k}$ [46].

Para la identificaciones Neuronal de (2.33) pueden ser usados dos modelos de (2.36)

MODELO PARALELO

$$x_{i,k+1} = w_{i,k}^T p_i(x_k) + w_i'^T \varphi''(x_k, u_k)$$

(2.38)

MODELO SERIE PARALELO

$$x_{i,k+1} = w_{i,k}^T p_i(X_k) + w_i'^T \varphi''(X_k, u_k)$$

(2.39)

Ley de aprendizaje en línea

Para el aprendizaje en línea de pesos RHONN, utilizamos un EFK [72]. Estos pesos se convierten en los estados a ser estimados el objetivo principal del EFK es encontrar los valores óptimos para el vector de peso $w_{i,k}$ de tal manera que la predicción de error es minimizada. La solución EFK para el problema de entrenamiento esta dado por la siguiente recursión:

$$\begin{aligned} M_{i,k} &= \left[R_{i,k} + H_{i,k}^T P_{i,k} H_{i,k} \right]^{-1} \\ K_{i,k} &= P_{i,k} H_{i,k} M_{i,k} \\ w_{i,k+1} &= w_{i,k} + \eta_i K_{i,k} e_{i,k} \\ P_{i,k+1} &= P_{i,k} - K_{i,k} H_{i,k}^T P_{i,k} + Q_{i,k} \end{aligned}$$

Donde el vector $w_{i,k}$ es el estimado del peso i -ésimo de la i -ésima neurona en la etapa de actualización K . Este estimado es una función de la ganancia Kalman K_i y el error de identificación neuronal $e_{i,k} = \chi_{i,k} - x_{i,k}$ donde $\chi_{i,k}$ es el estado de planta y x_i es el estado de la RHONN.

La ganancia de Kalman es una función de la matriz de covarianza de error aproximado P_i , una matriz de derivados de salidas de la red con respecto a todos los parámetros de peso entrenables H_i

$$H_{i,k} = \begin{bmatrix} \frac{\partial x_{i,k}}{\partial w_{i,k}} \end{bmatrix}^T \quad (2.41)$$

Una matriz de escala global M_i , aquí Q_i es la matriz de covarianza del proceso de ruido y R_i es la matriz de covarianza de ruido de medición. Como un parámetro adicional introduciremos la tasa de aprendizaje η_i de tal manera que $0 \leq \eta_i \leq 1$. Usualmente P_i, Q_i y R_i son inicializadas como matrices diagonales con entradas $P_i(0), Q_i(0)$ y $R_i(0)$ respectivamente. Definimos Q_i y R_i como fijas. Durante el entrenamiento los valores de H_i, K_i y P_i se aseguran para ser acotados.[46]

Teorema 2.4(Identificación Neuronal [46]. La RHONN (2.34) entrenada con el algoritmo basado en EFK (2.4) para identificar la planta no lineal (2.33) asegura que el error de identificación neuronal $e_{i,k}$ es semi globalmente uniforme en última instancia limitado, por otra parte los pesos RHONN permanecen acotados

Capítulo 3

Control Óptimo Inverso. Usando CLF

Motivados por los márgenes de estabilidad favorables de los sistemas de control óptimo sintetizamos una ley de control de retroalimentación, que será óptima con respecto a una función de costo funcional. Al mismo tiempo queremos evitar la difícil tarea de resolver la ecuación parcial diferencial HJB. En el problema de control óptimo inverso, un candidato CLF se utiliza para construir una ley de control óptima directamente sin resolver la ecuación HJB asociada

3.1 Control óptimo inverso vía CLF

Nos enfocaremos en la optimización inversa por que evita resolver las ecuaciones parciales diferenciales HJB y todavía permite obtener márgenes de estabilidad de tipo Kalman.

En contraste con el control óptimo inverso a través de enfoque pasividad, en el que una función de almacenamiento se utiliza como un candidato CLF y la ley de control óptimo inversa se selecciona como la realimentación de la salida, para el control óptimo inverso vía CLF, la ley de control se obtiene como resultado de la resolución de la ecuación de Bellman. Entonces se propone un candidato CLF para la ley de control obtenida de tal manera que establezca el sistema y se minimice el costo funcional*.

Por esta disertación un candidato cuadrático CLF es usado para sintetizar la ley de control óptimo inverso. Se establecen las siguientes suposiciones y definiciones las cuales permiten solucionar la ley de control óptimo inversa a través del enfoque CLF.

Suposición 4.1. El estado completo del sistema es medible(2.2)

Definición 4.1. (Ley de control óptimo inverso) definimos la ley de control:

$$u_k^* = -\frac{1}{2} R^{-1}(x_k) g^T(x_k) \frac{\partial V(x_{k+1})}{\partial x_{k+1}} \quad (3.1)$$

es óptimo inversa (a nivel global) si:

- (i) Logra estabilidad (global) asintótica de $x = 0$ para el sistema (2.2)
- (ii) $V(x_k)$ es una función definida positiva (acotada radialmente) de tal manera que la desigualdad

$$\bar{V} := V(x_{k+1}) - V(x_k) + u_k^T R(x_k) u_k^* \leq 0 \quad (3.2)$$

se cumpla.

Cuando seleccionamos $l(x_k) : -\bar{V} \geq 0$, entonces $V(x_k)$ es una solución para la ecuación HJB

$$l(x_k) + V(x_{k+1}) - V(x_k) + \frac{1}{4} \frac{\partial V^T(x_{k+1})}{\partial x_{k+1}} g(x_k) R^{-1}(x_k) \frac{\partial V(x_{k+1})}{\partial x_{k+1}} = 0$$

Podemos establecer las principales diferencias conceptuales entre control óptimo y control óptimo inverso:

- Para el control óptimo los índices de costos significativos $l(x_k) > 0$ y $R(x_k) > 0$ se les da prioridad*, por lo tanto son usados para calcular $u(x_k)$ y $(V(x_k))$ por medio de la solución de la ecuación HJB
- Para el control óptimo inverso, una función CLF $(V(x_k))$ y el índice de costos significativos $R(x_k)$ se les da prioridad*, y entonces estas funciones se utilizan para calcular la ley de control inverso $u^*(x_k)$ y el costo de índice significativo $l(x_k)$ definido como $l(x_k) : -\bar{V}$

Como se establece en la definición 4.1 el problema del control óptimo inverso se basa en el conocimiento de $V(x_k)$. Por lo tanto proponemos un CLF $V(x_k)$ de tal manera que (i) y (ii) sean garantizados. Es decir, en lugar de resolver (2.10) para $V(x_k)$ proponemos una función de control Lyapunov $V(x_k)$ con la forma:

$$V(x_k) = \frac{1}{2} x_k^T P x_k, \quad P = P^T > 0$$

Para la ley de control (4.1) con el fin de asegurar la estabilidad con el punto de equilibrio $x_k = 0$ del sistema (2.2) el cual se lograra definiendo una matriz aproximada P , por otra parte se establecerá la ley de control (4.1) con (4.3) que se conoce como la ley de control óptimo inversa, optimiza un coste significativo funcional de la forma (2.3).

Consecuentemente considerando $V(x_k)$ como en (4.3), la ley de control (4.1) toma la siguiente forma:

$$\begin{aligned} \alpha(x_k) &:= u_k' \\ &= -\frac{1}{2} (R(x_k) + P_2(x_k))^{-1} P_1(x_k) \end{aligned}$$

donde $P_1(x_k) = g^T(x_k) P f(x_k)$ y $P_2(x_k) = \frac{1}{2} g^T(x_k) P g(x_k)$. Vale la pena señalar que P y $R(x_k)$ son matrices simétricas definidas positivas, por lo tanto, se asegura la existencia de la inversa de (4.4).

Una vez que hemos propuesto un CLF para resolver el control óptimo inverso de acuerdo a la definición (4.1), se presenta la solución respectiva, para la cual P es considerada una matriz fija.

Teorema 3.1 considere el sistema no lineal de tiempo-discreto afin (2.2), si existe una matriz $P = P^T > 0$ de tal manera que la siguiente desigualdad se mantiene:

$$V_r(x_k) - \frac{1}{4} P_1^T(x_k) (R(x_k) + P_2(x_k))^{-1} P_1(x_k) \leq -\zeta_Q \|x_k\|^2$$

Para la ley de control (4.1) con el fin de asegurar la estabilidad del punto de equilibrio

3.2 Algoritmo de Gradiente De Velocidad

Dado (2.14), 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 permite calcular un valor variante en el tiempo para $P(k)$, la cual asegura estabilidad para el sistema (2.8) mediante el algoritmo GV. En [9] una aplicación en tiempo discreto para el algoritmo de gradiente de velocidad es formulada para encontrar una ley de control $u(k)$ que asegura el objetivo del control, como: $Q(x(k+1)) \leq \Delta$ para $k \geq k^*$ (2.15) 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 [9], considerando la ley de control de (2.14) con Δ en (2.15) como una función de estado dependiente $\Delta(x(k))$

La ley de control redefinida para el algoritmo de gradiente de velocidad depende todo el tiempo de la matriz $P(k)$. Por lo cual definimos la matriz $P(k)$ como:

$$P(k) = p(k)P' \quad \forall k \tag{2.16}$$

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

$$u(k) = -\frac{p(k)}{2} (R(x(k)) + \frac{p(k)}{2} P_1^*)^{-1} P_2^* \tag{2.17}$$

Donde:

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

De lo anterior podemos decir que el algoritmo GV es reformulado para el problema del Control optimo inverso.

Definición 2 (Función objetivo de GV)

Consideremos un parámetro variante en el tiempo $p(k) \in P \subset \mathbb{R}^+$ con $p(k) > 0$ para todo k , y P un conjunto de valores admisibles para p_k [17]. Una función no negativa $Q: \mathbb{R}^n \times \mathbb{R} \rightarrow \mathbb{R}$ de la forma

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

donde $V_{sg}(x(k+1)) = \frac{1}{2} x^T(k+1) P' x(k+1)$ y con $x(k+1)$ como se define en (2.8), es referido como la función objetivo de GV para el sistema (2.8). Definimos $Q(k(p)) := Q(x(k), p(k))$

Definición 3 (Objetivo de control GV)

Consideramos una constante $p^* \in P$. El objetivo de control GV para el sistema (2.8) con (2.17) es definido encontrando $p(k)$, de modo que la función objetivo de GV $Q(k(p))$ [17], como en (2.18), satisface:

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

donde

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

Con $V_{sg}(x(k)) = \frac{1}{2} x^T P' x(k)$ y $u(k)$ como se define en (2.17) $k \in \mathbb{Z}^+$ el tiempo al cual el objetivo de control GV es alcanzado.

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

Proposición 1 Considere un sistema discreto no lineal de la forma (2.8) con (2.17) como entrada. Sea Q función objetivo GV definida en (2), y denotada $Q(k(p))$. Sea $p, p^* \in P$ valores constantes positivos y $\Delta(x(k))$ una función definida positiva con $\Delta(0) = 0$ y q^* una constante positiva suficientemente pequeña. Suponemos que:

Existe p^* y ϵ^* tal que

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

y

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

Para $p(k) \in P$:

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

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

Entonces, para cualquier condición inicial $p(0) > 0$, existe una $k^* \in \mathbb{Z}^+$ tal que la meta de control (2.15) es alcanzada por medio de la siguiente dinámica de variación del parámetro $p(k)$:

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

con

$$\begin{aligned} \gamma_{d(k)} &= \gamma_c \delta(k) |\nabla(\rho)Q(k(p))|^{-2} \\ 0 < \gamma_c &\leq 2\Delta(x(k)) \end{aligned}$$

y

$$\delta(k) = \begin{cases} 1 \\ 0 \end{cases} \text{ para } Q(p(k)) > \Delta(x(k))$$

Finalmente, para $k \geq k^*$, $p(k)$ se convierte en un valor constante denotado como p y el Algoritmo GV termina.

Observación 2 Con $Q(x(k), p(k))$ como se definió en (2.18), la variación dinámica del parámetro $p(k)$ en (2.23) resulta en

$$p(k+1) = p(k) + P^*$$

Donde

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

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 (2.19) es alcanzado,, entonces $p(k) = p$ para $k \geq k^*$. Esto es, la matriz $P(k)$ en (2.17) es considerada constante y $P(k) = P$ donde P es calculada como $P = pP'$, con P' como una matriz definida positiva. Bajo estas circunstancias, se obtiene

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

donde

$$P_1(x(k)) = g^T(x(k))P'f(x(k)) \quad \text{y} \quad P_2(x(k)) = \frac{1}{2}g^T(x(k))P_g(x(k))$$

Capítulo 4

Implementación en Tiempo Real

En este capítulo se presenta el desarrollo del proyecto de control óptimo inverso en tiempo real de generador síncrono, se propone el modelo neuronal para la estimación de estados x_1 (ángulo de rotor), x_2 (Velocidad del rotor), x_3 (voltaje de estator), la ley de control, el algoritmo de gradiente de velocidad, características del Generador, programa de control en "Labview", y resultados obtenidos.

4.1 Estimación de los Estados del Sistema.

Se definen las siguientes variables de estado:

x_1 = Ángulo del rotor

x_2 = Velocidad angular del rotor

x_3 = Voltaje del estator

Para identificar el modelo en tiempo discreto del generador síncrono, se propone una Red Neuronal de Orden Superior (RHONN por sus siglas en inglés) como sigue:

$$\begin{aligned}\bar{x}_{1,k+1} &= w_{11,k}S(x_{1,k}) + w_{12,k}S(x_{2,k}) \\ \bar{x}_{2,k+1} &= w_{21,k}S(x_{1,k})^6 + w_{22,k}S(x_{2,k})^2 + w_{23,k}S(x_{3,k}) \\ \bar{x}_{3,k+1} &= w_{31,k}S(x_{1,k})^2 + w_{32,k}S(x_{2,k}) + w_{33,k}S(x_{3,k})^2 + w_{34}u_k\end{aligned}$$

donde \bar{x}_i estima el estado x_i ($i=1,2,3$), y, w_{34} es un parámetro fijo para asegurar la controlabilidad, seleccionado como $w_{34}=0.5$, el sistema puede ser reescrito como:

$$x_{k+1} = f(x_k) + g(x_k)u_k$$

con

$$f(x_k) = \begin{bmatrix} w_{11,k}S(x_{1,k}) + w_{12,k}S(x_{2,k}) \\ w_{21,k}S(x_{1,k})^6 + w_{22,k}S(x_{2,k})^2 + w_{23,k}S(x_{3,k}) \\ w_{31,k}S(x_{1,k})^2 + w_{32,k}S(x_{2,k}) + w_{33,k}S(x_{3,k})^2 \end{bmatrix}$$

y

$$g(x_k) = \begin{bmatrix} 0 \\ 0 \\ w_{34} \end{bmatrix}$$

donde

$$S(\zeta) = \frac{1}{1 + \exp(-\beta\zeta)}, \beta > 0$$

En la figura 4.1 se presenta el esquema de control completo:

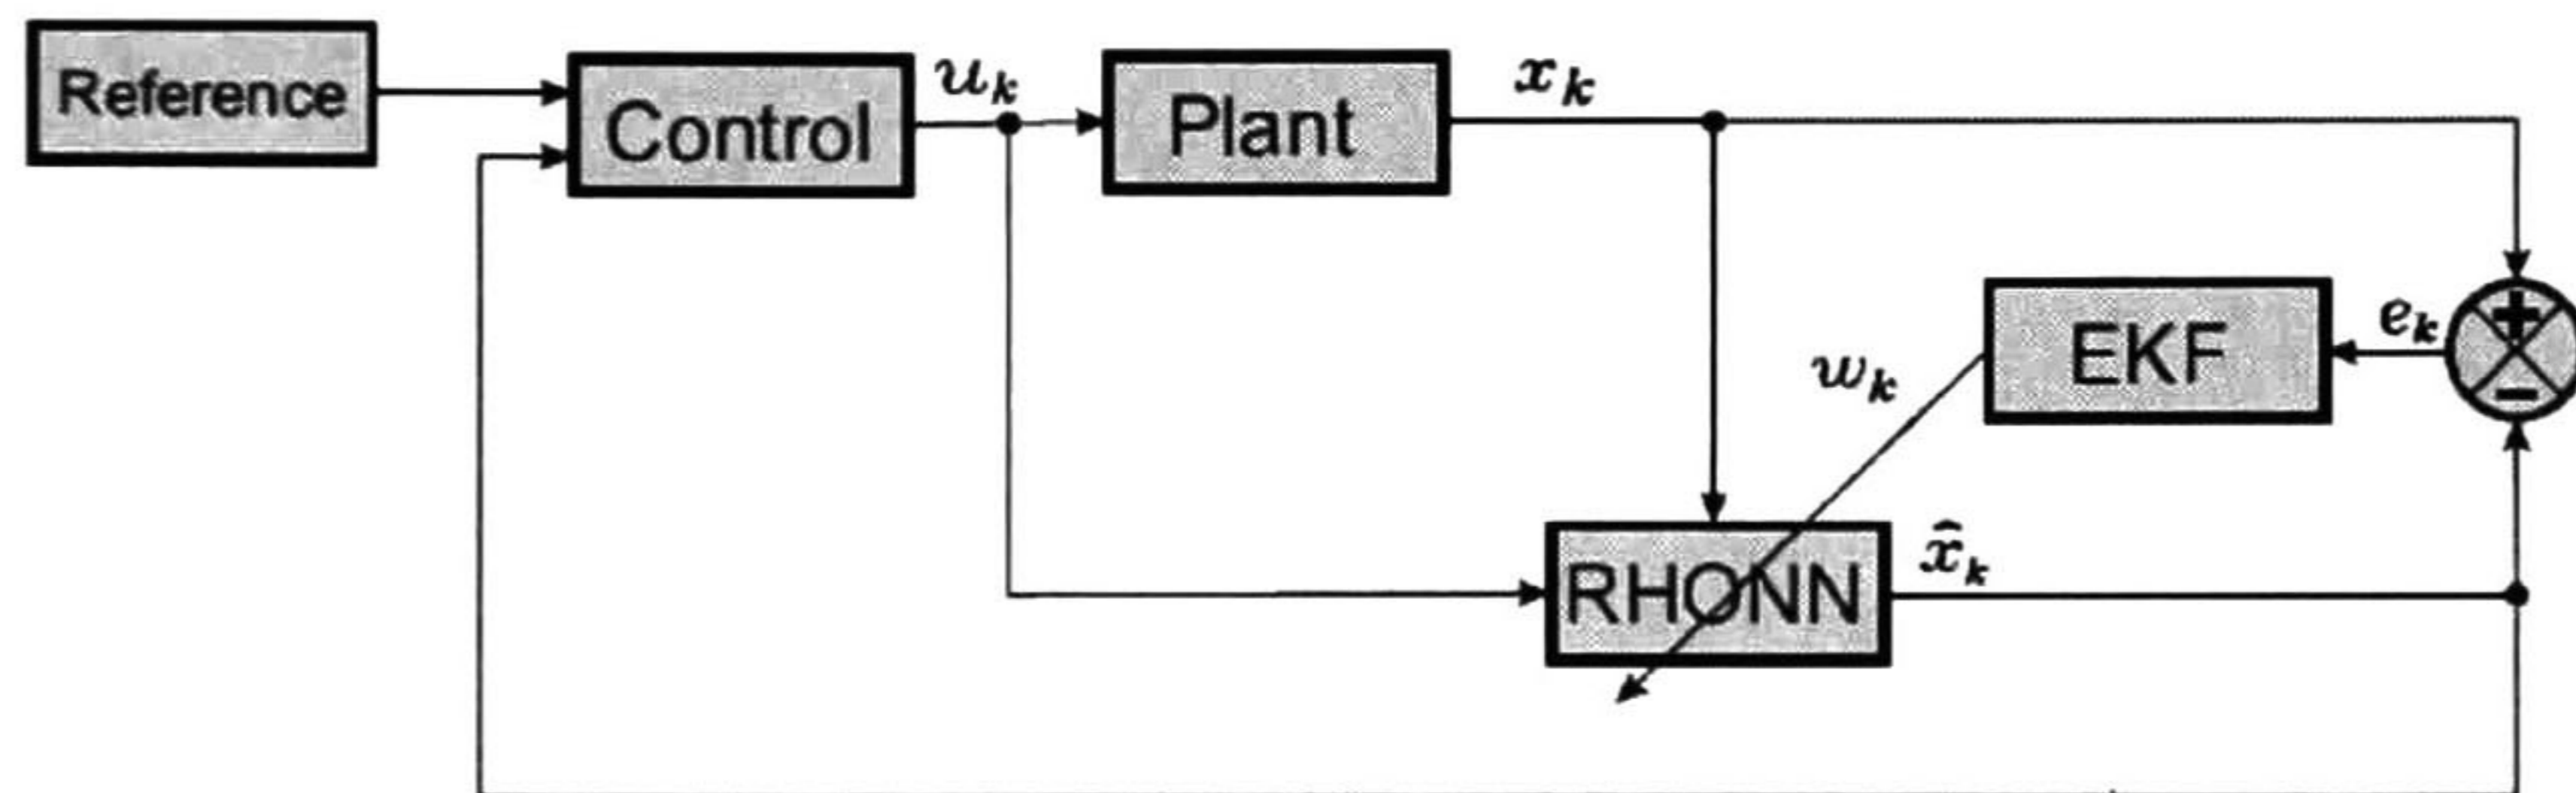


Fig. 4.1 Esquema de control

Se utiliza la ley de control óptimo inverso basada en una CLF:

$$u_k^* = -\frac{1}{2} (R(z_k) + \frac{1}{2} g^T(x_k) P_k g(x_k))^{-1} g^T(x_k) P_k (f(x_k) - x_{\delta,k+1})$$

donde $x_{\delta,k+1}$ es la señal de referencia, y con

$$P_{k+1} = P_k + 8\gamma_{d,k} \frac{f^T(x_k) P_k g(x_k) R(x_k)^2 g^T(x_k) f(x_k)}{(2R(x_k) + P_k g^T(x_k) P_k g(x_k))^3}$$

Se realizó la simulación en MATLAB de la estabilización de un generador síncrono mediante Control Optimo Inverso con estimador de estados mediante una Red Neuronal Recursiva de Orden Superior de acuerdo al siguiente modelo:

Modelo:

$$x_{1,k+1} = f^1(\bar{x}_k) + \tau x_{2,k}$$

$$x_{2,k+1} = f^2(\bar{x}_k) + \tau m_2 x_{3,k}$$

$$x_{3,k+1} = f^3(\bar{x}_k) + \tau m_6 u_k$$

$$f^1(\bar{x}_k) = x_{1,k}$$

$$f^2(\bar{x}_k) = x_{2,k} + \tau [m_1 + (m_2 E_q^* + m_3 \cos(\bar{x}_1) \sin(\bar{x}_1))]$$

$$f^3(\bar{x}_k) = x_{3,k} + \tau [m_4 (x_{3,k} + E_q^*) + m_5 \cos(\bar{x}_1) + m_6 E_{fd}^*]$$

$$\bar{x}_1 = x_{1,k} + \delta^*$$

$$m_1 = T_m / M$$

$$m_2 = -V / M X_d'$$

$$m_3 = (V^2 / M)(1 / X_d' - 1 / X_q')$$

$$m_4 = -X_d' / (T_{do}') X_d'$$

$$m_5 = (X_d' - X_q') / (T_{do}' X_d') V$$

$$m_6 = 1 / T_{do}'$$

donde:

$$x_1 = \Delta \delta = \delta - \delta^*$$

$$x_2 = \Delta \omega = \omega - \omega^*$$

$$x_3 = \Delta E_q' = E_q' - E_q^*$$

$(\delta^*, \omega^*, E_q^*)$, son las variables de estado en el punto de equilibrio.

$\tau = 0.01$ Tiempo de muestreo

Parámetros

$T_m = 1$ Par mecánico

$M = 0.033$ Constante de inercia

$\omega = 1$ Velocidad síncrona

$T_{do} = 0.033$	Constante de tiempo de transitorio en circuito abierto
$X_q = 0.9$	Reactancia en cuadratura
$X_d = X_q$	Reactancia aumentada
$X_{dp} = 0.3$	Reactancia transitoria aumentada
$V = 1$	Voltaje de Bus
$E_{fd}^* = 1.1773$	Voltaje de campo constante
$\delta^* = 0.870204$	Desplazamiento angular del rotor (power angle)
$\omega = 1$	Velocidad angular del rotor en el punto de Equilibrio
$E_q^* = 0.822213$	Voltaje de estator en el punto de Equilibrio

$$P' = \begin{pmatrix} 1.5 & 1 & 0.5 \\ 1 & 1.5 & 1 \\ 0.5 & 1 & 1.5 \end{pmatrix}$$

$$R(x_k) = 1$$

Con el propósito de ilustrar la robustez del controlador propuesto, se consideran las siguientes etapas en el proceso de simulación:

Etapas 1: Son utilizados los parámetros arriba indicados al inicio de la simulación.

Etapas 2: Ocurre una falla de cortocircuito en 1.5 s, la cual es equivalente al cambio en la reactancia aumentada X_d , desde $X_d = 0.9$ a $X_d = 0.1$

Etapas 3: Se remueve la falla de cortocircuito en 1.6 s.

Etapas 4: Se introduce un disturbio mecánico de potencia al cambiar T_m , desde $T_m = 1$ a $T_m = 1.2$ en 3.5 s.

Etapas 5: El disturbio es removido en 3.6 s.

Al correr el programa se obtuvieron los siguientes resultados:




Fig. 4.2 Gráficas de las tres señales de variables de estado




Fig. 4.3 Gráficas de Señales: Voltaje de excitación, $p(k)$ y Costo funcional.

4.2 Características del Generador e interface de excitación.

Se utilizó un generador síncrono Trifásico de 12v, 720 VA, 12 polos, impulsado por un motor de inducción de monofásico de 1760 RPM.

La frecuencia de salida con esta velocidad y numero de polos resultó: $f=176$ Hz.

La interface o driver para el devanado de excitación consistió en un modulador PWM con entrada 0 a 5 v y salida de 0T a 1T, a frecuencia = 20 KHz.

4.3 Programa de control en Labview, y resultados Obtenidos.

A continuación se presentan el programa utilizado en Labview para el control, así como sus pantallas o panel de instrumentos:

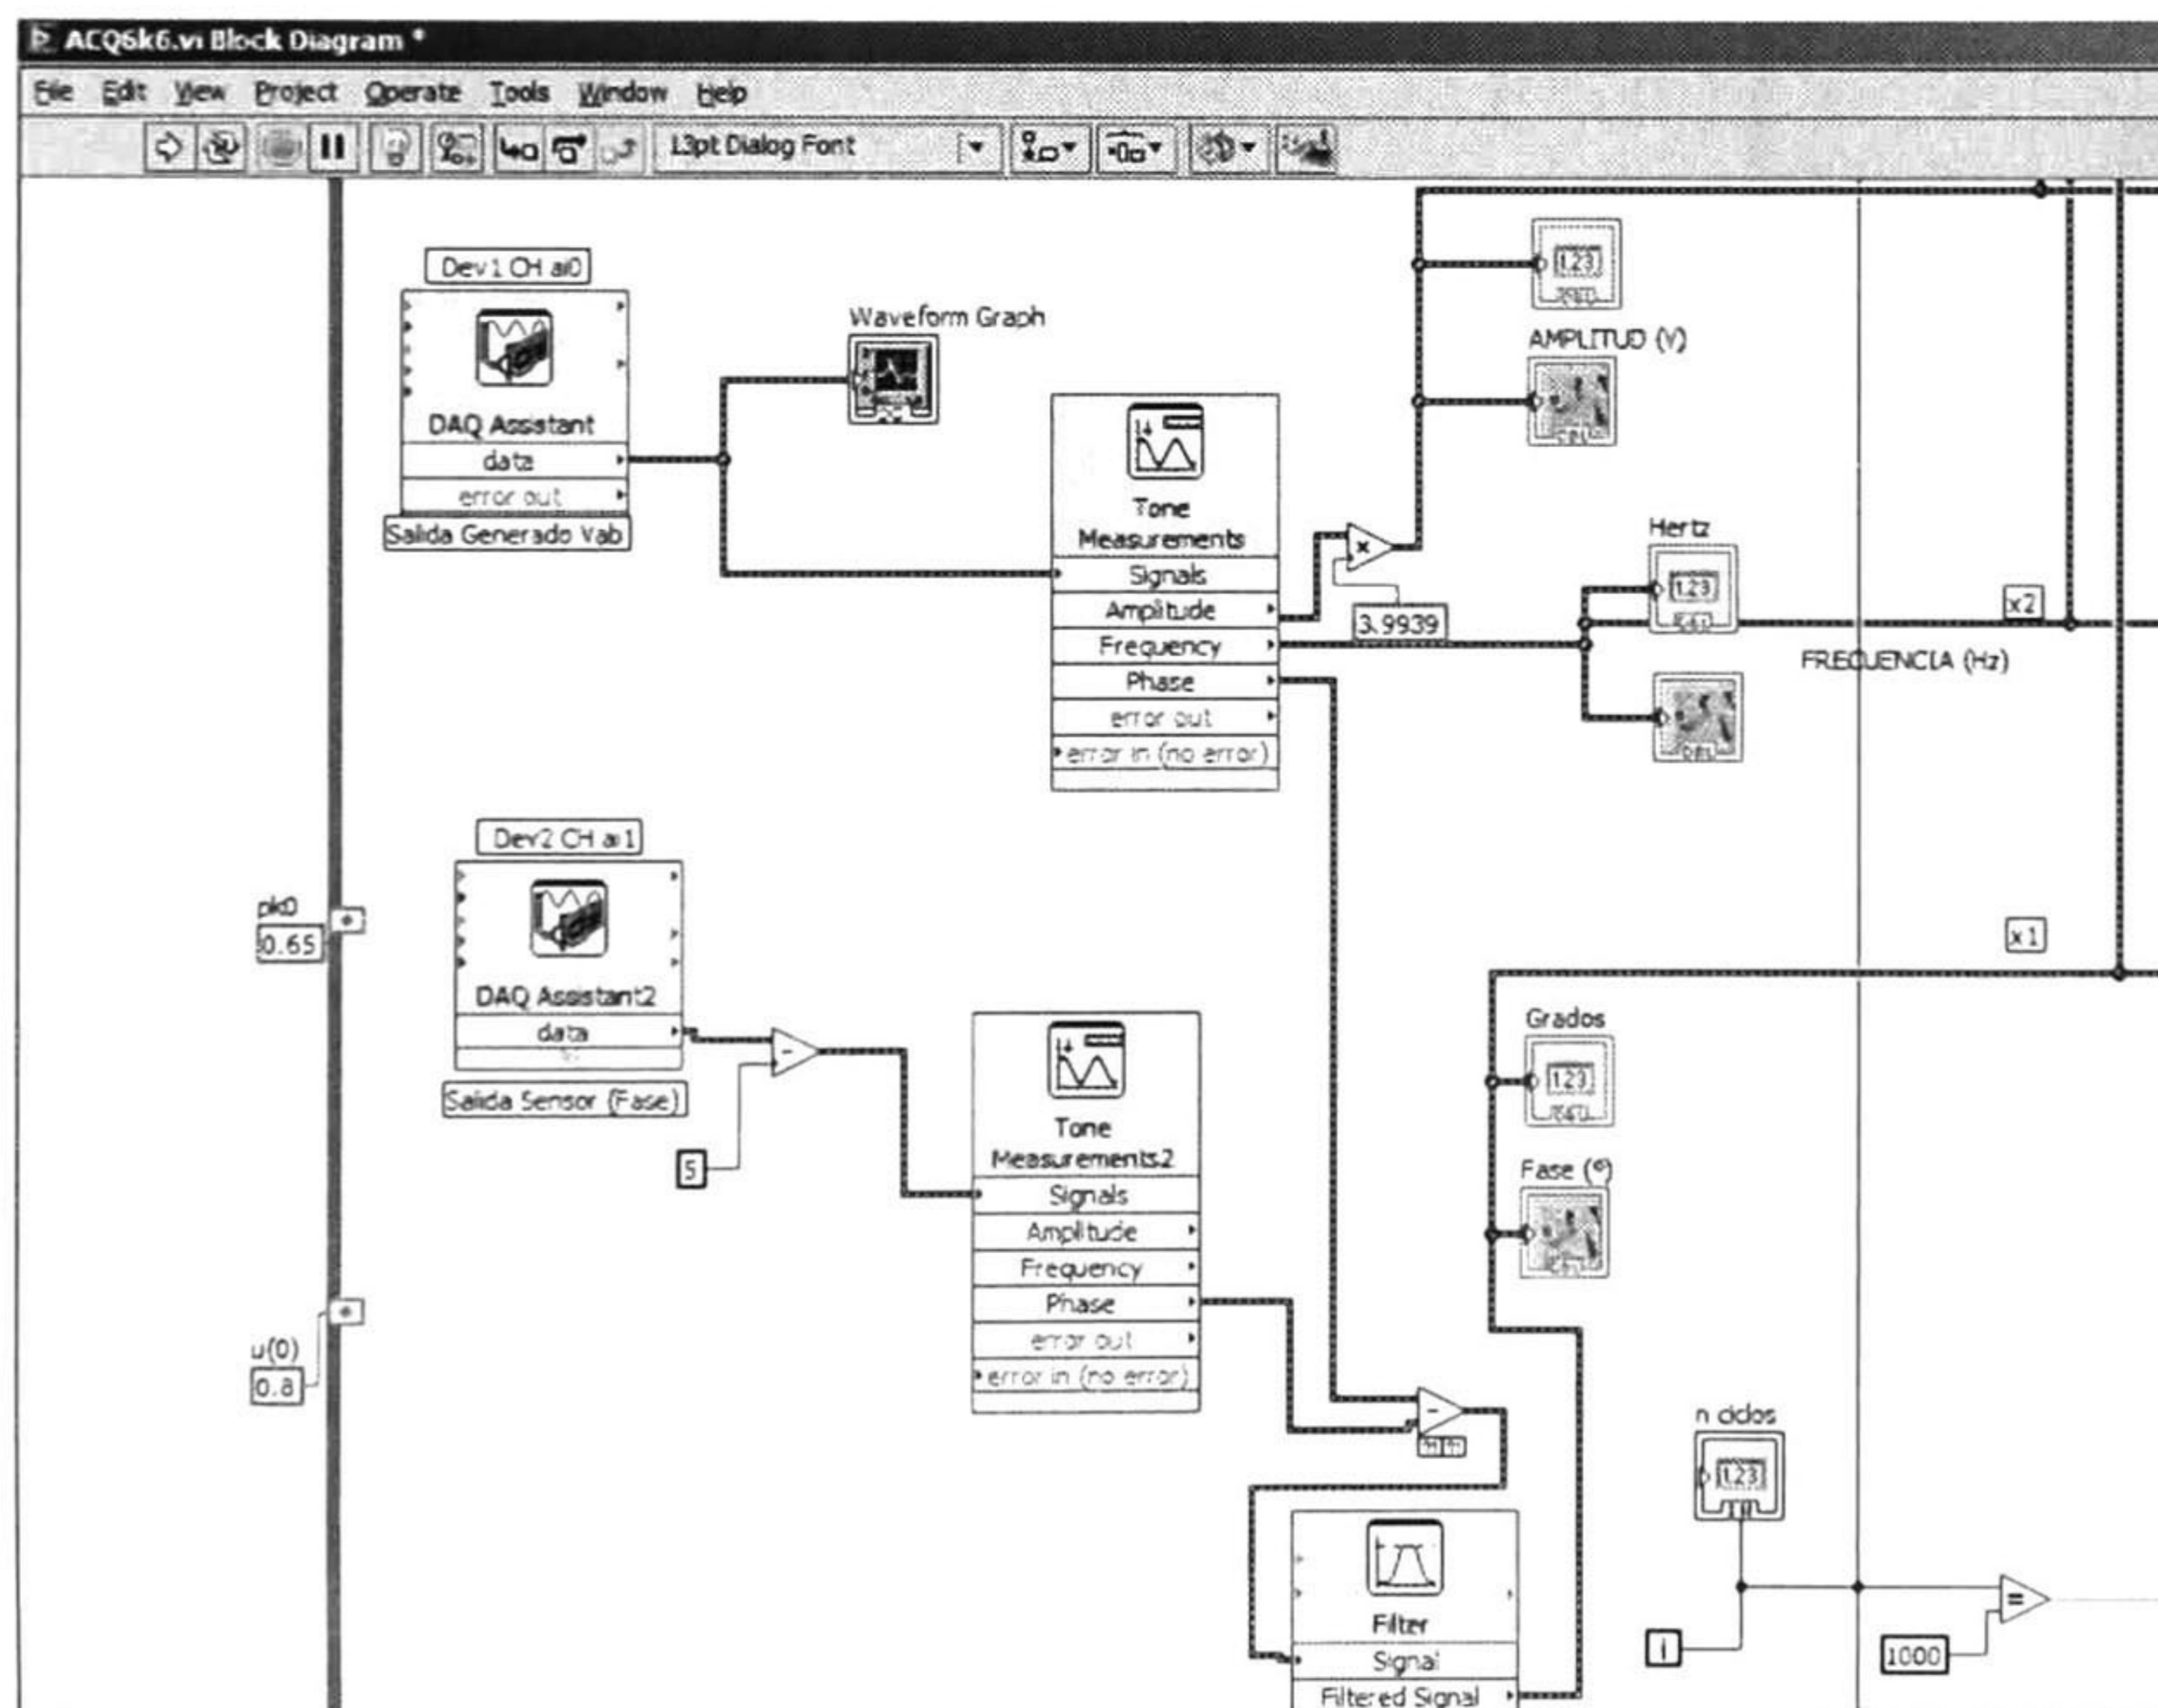


Fig. 4.4 Etapas de adquisición y tratamiento de señales de entrada del programa

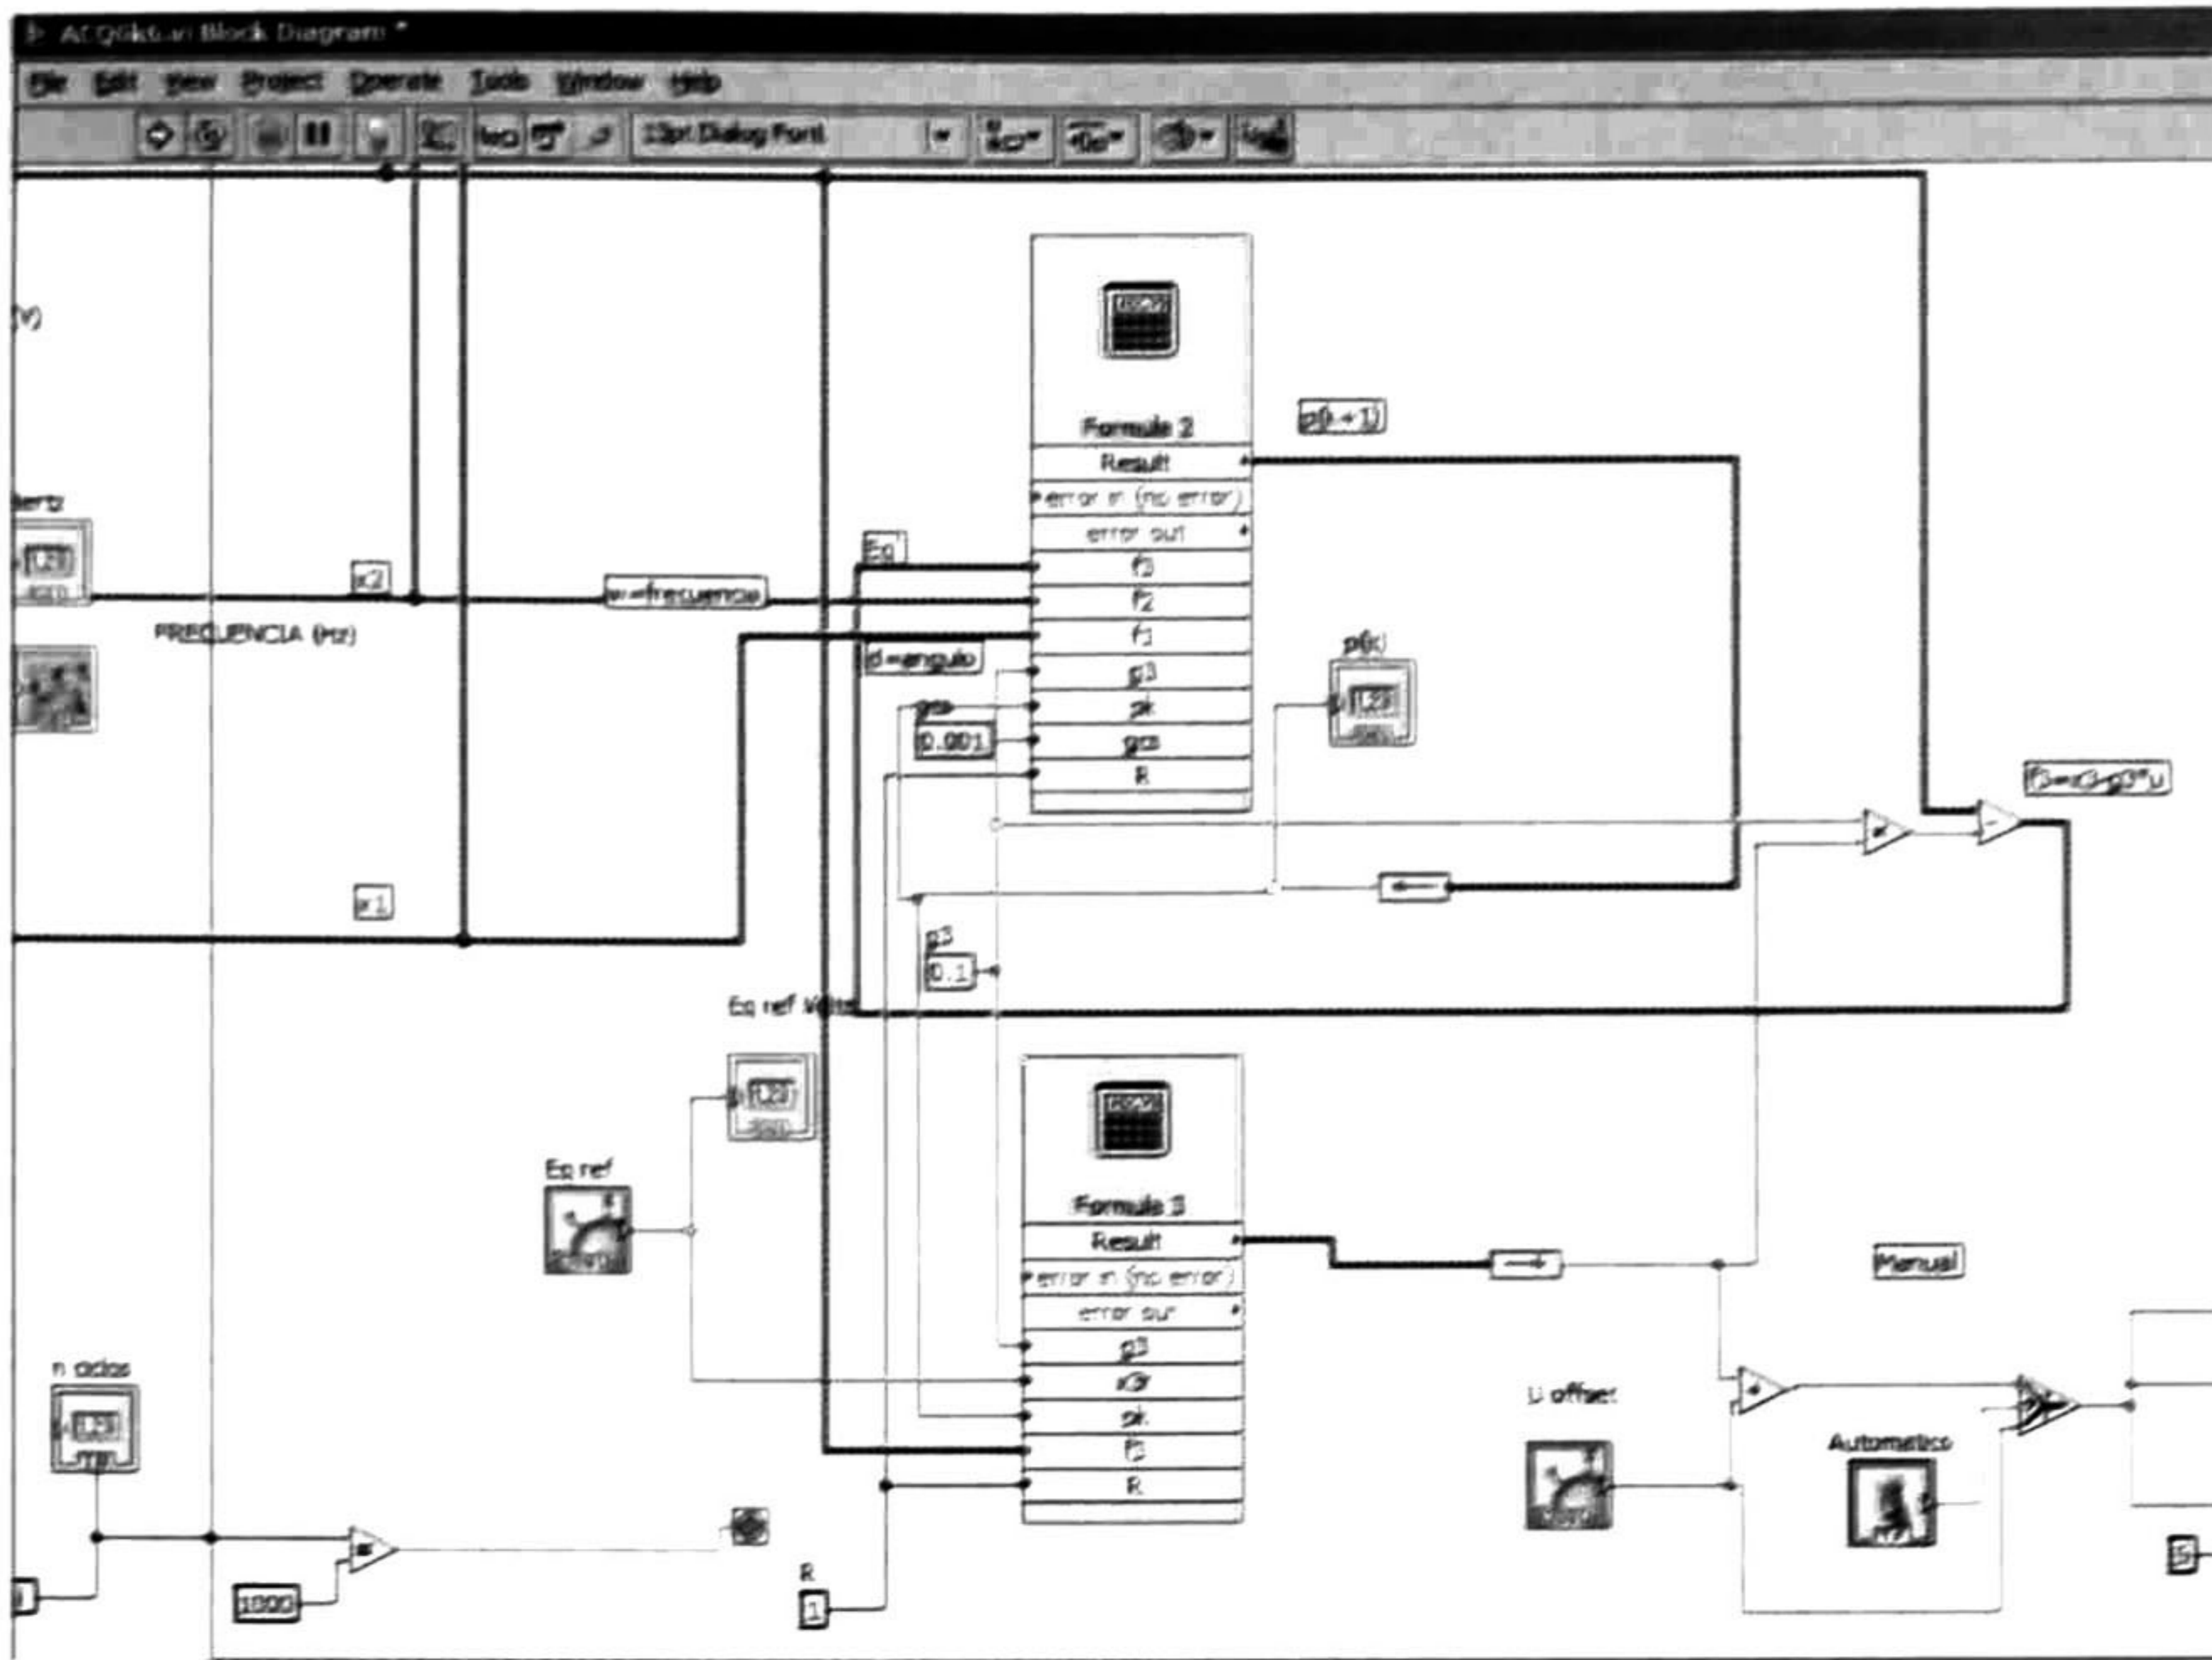


Fig 4.5 Etapa de control de Programa en Labview

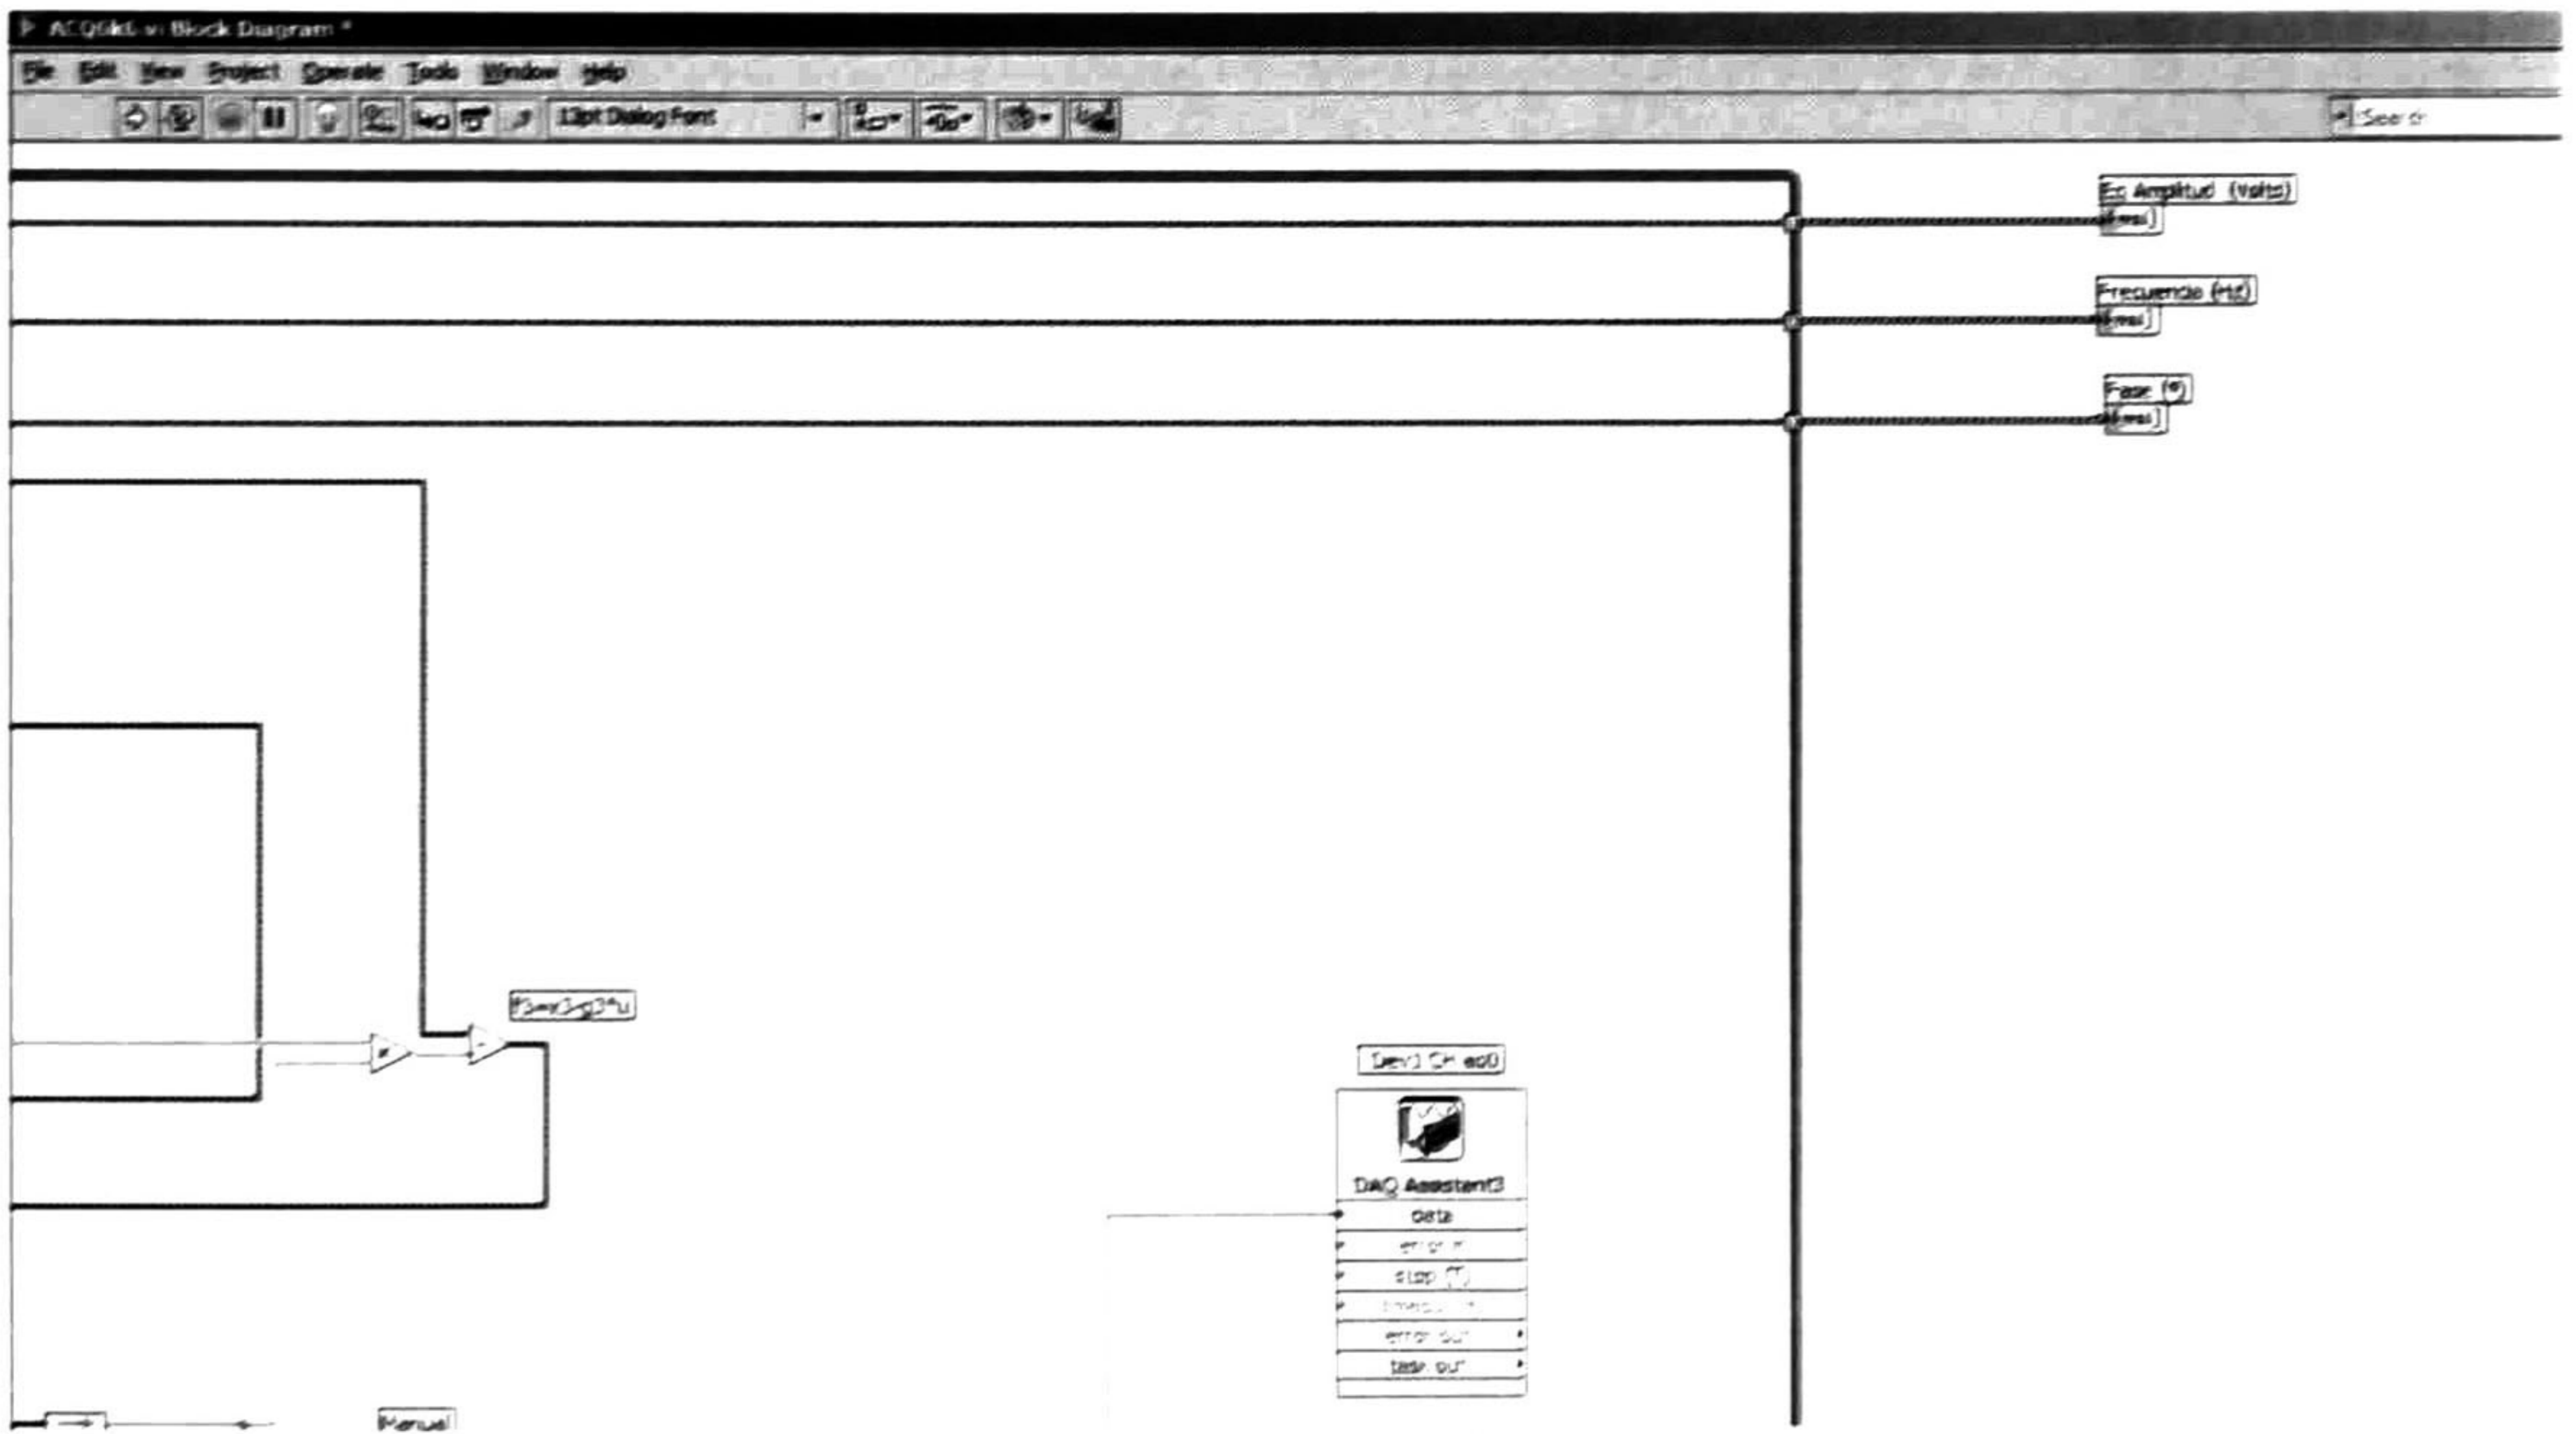


Fig 4.6 Etapa de Salida y despliegue del programa en Labview

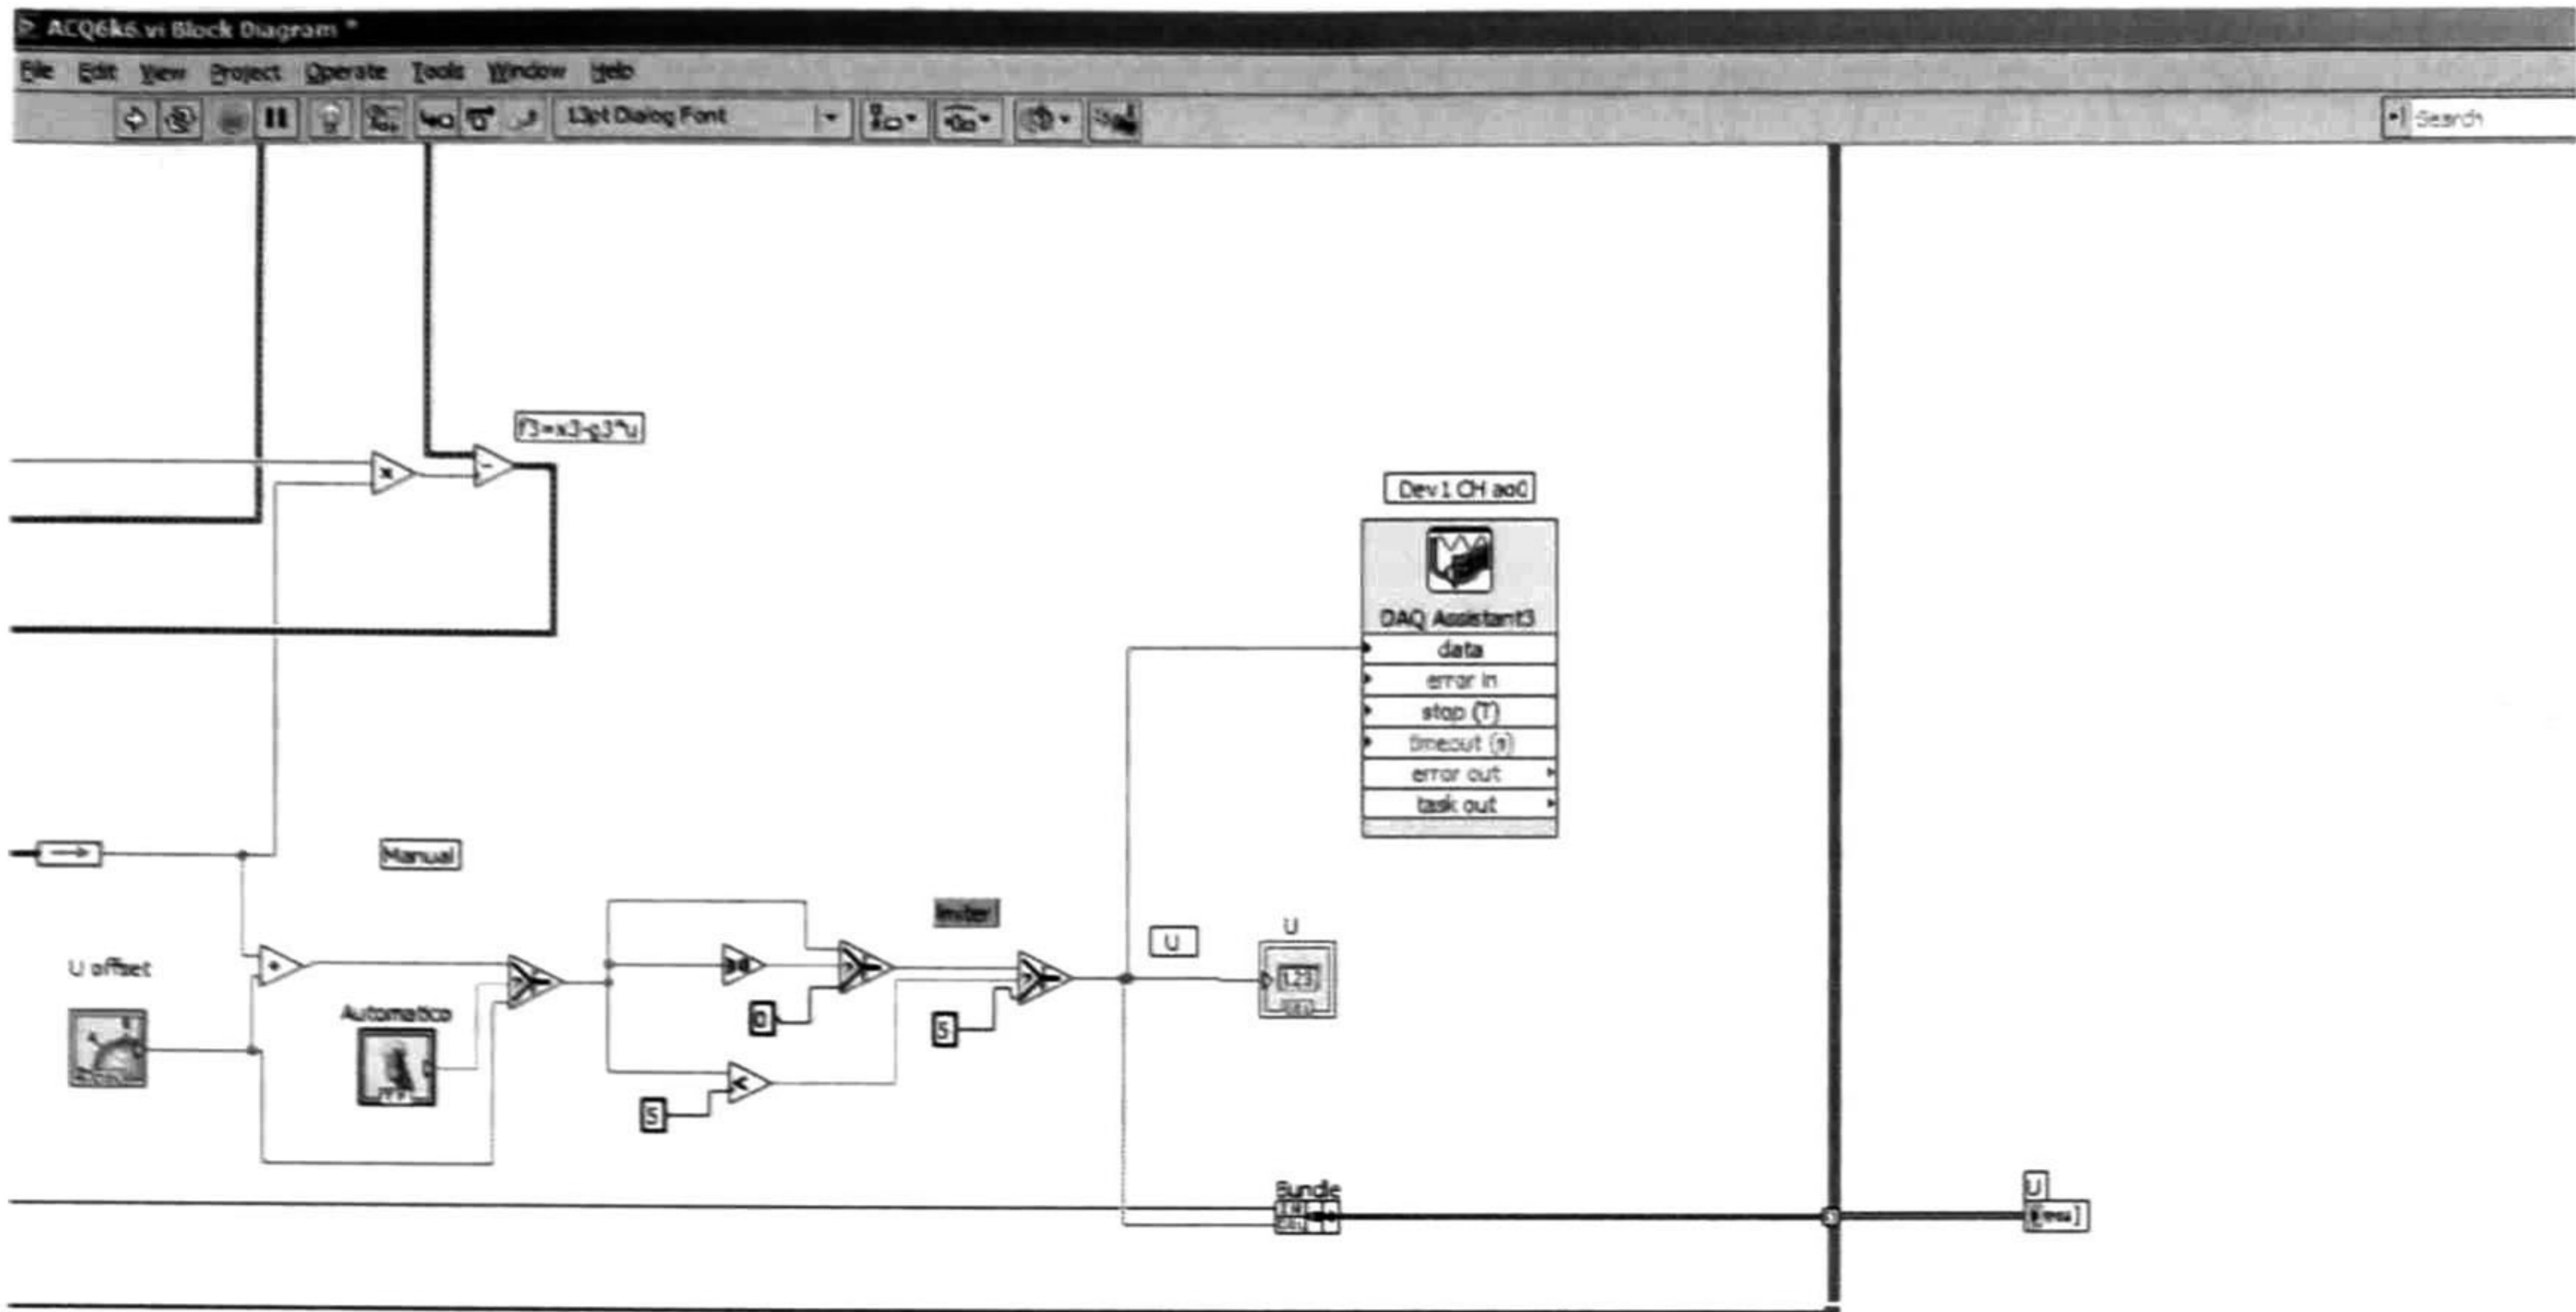


Fig. 4.7 Etapa de Salida y despliegue del programa en Labview

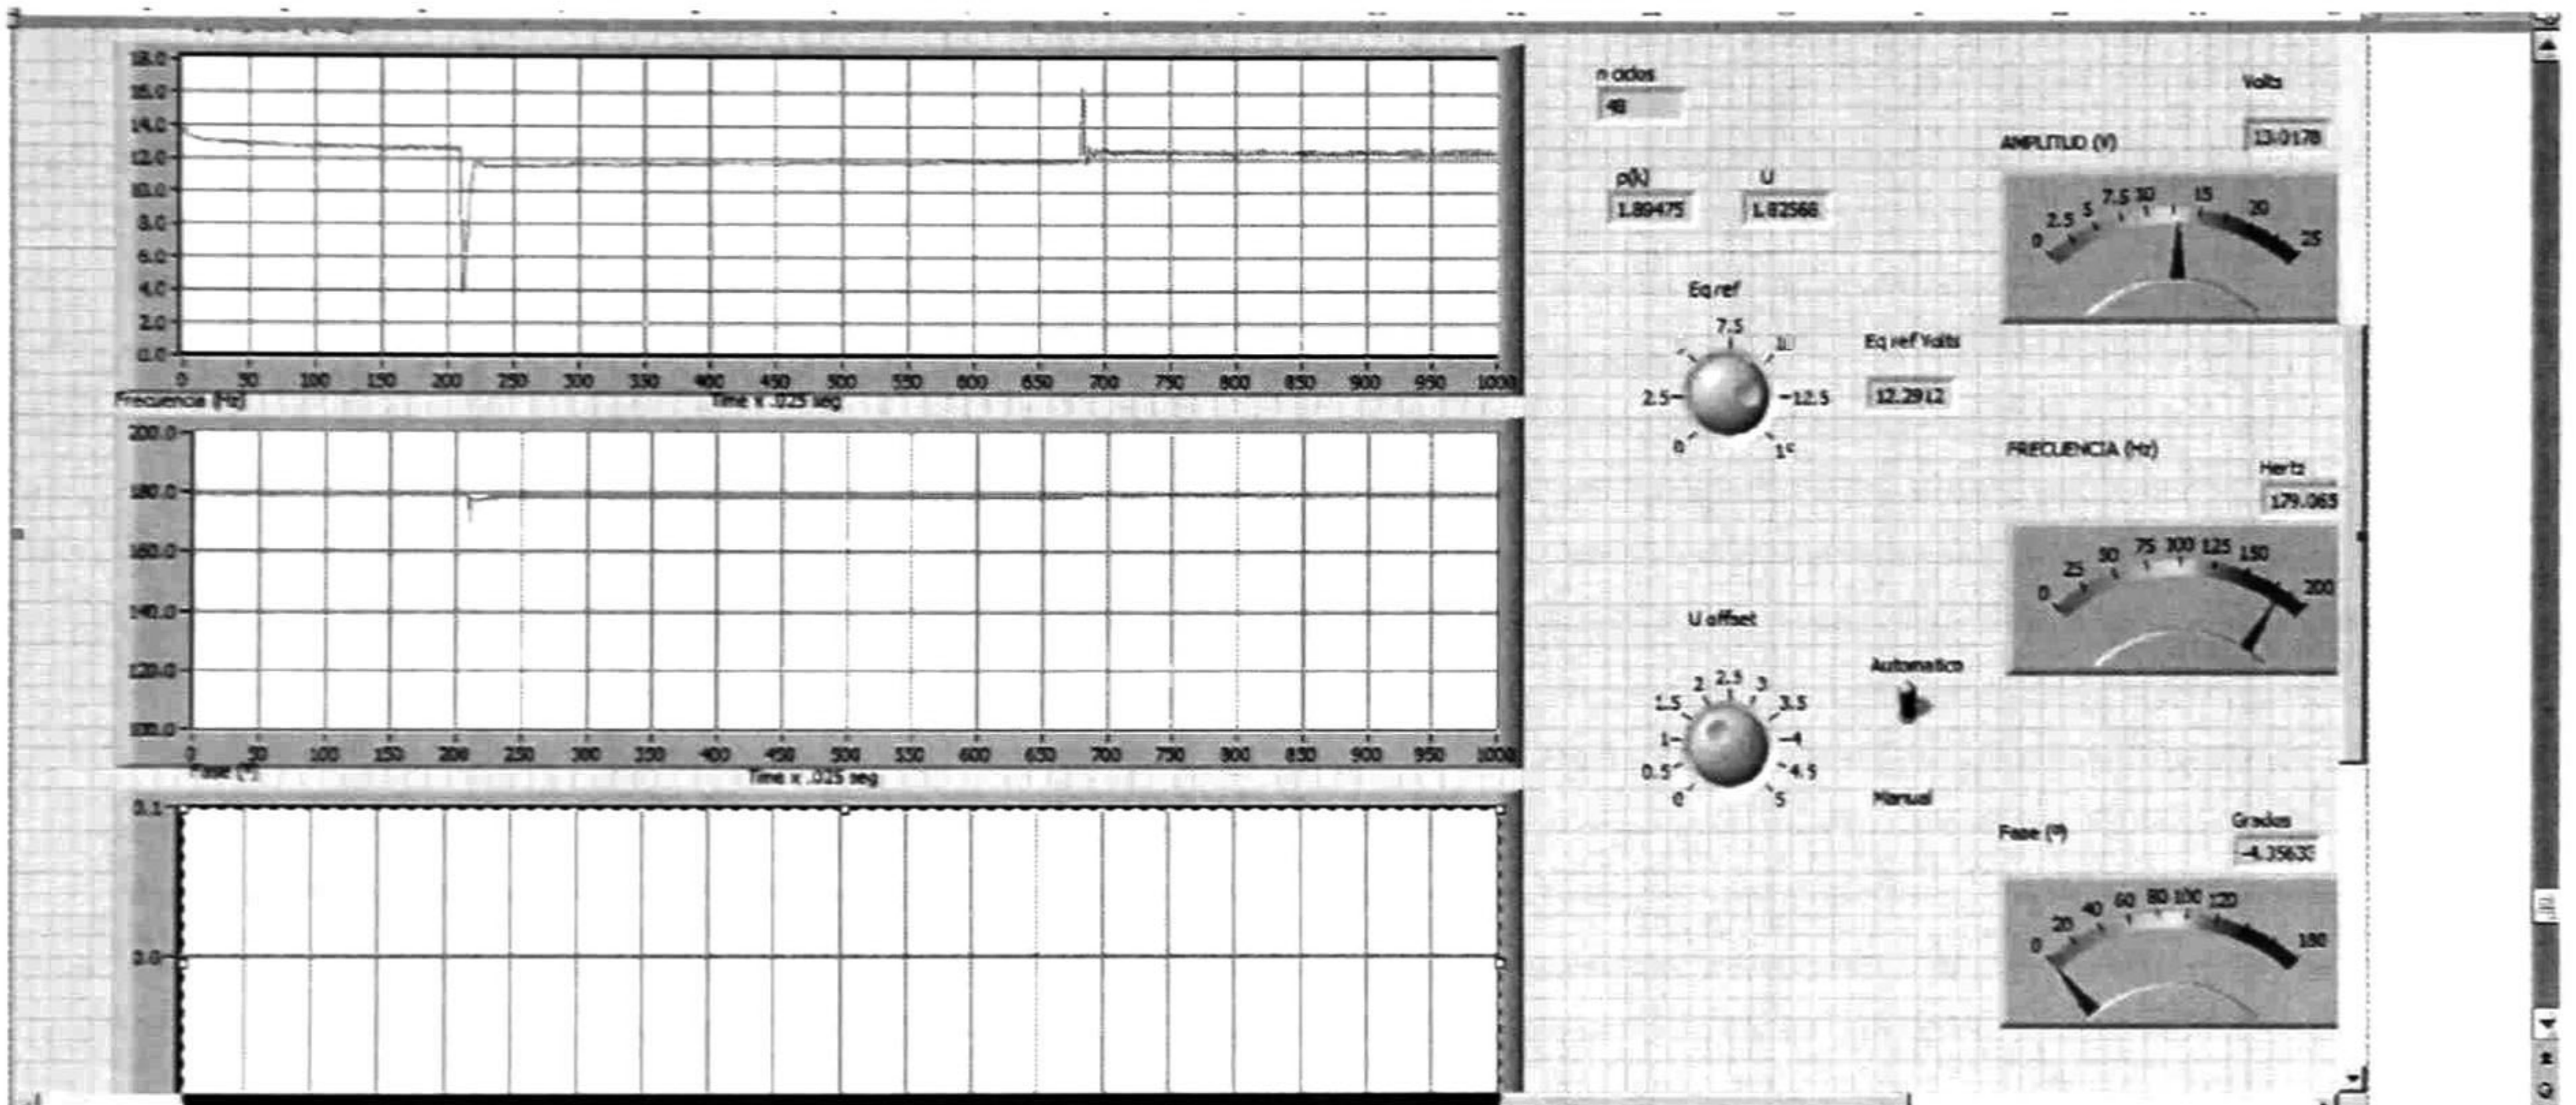


Fig. 4.8 Panel Frontal o de Instrumentos




Fig. 4.9 Continuación panel de instrumentos

Después de Poner en marcha el generador excitado, se agregó una perturbación con un incremento de carga de 0 a 250 watts, obteniéndose el siguiente resultado en el voltaje del estator (E_q) y señal de control (u):




Fig. 4.10 Respuesta del Generador con el controlador frente a perturbaciones en la carga.

Se puede observar en las figuras 5.7 y 5.8 como el sistema se recupera rápidamente y de forma muy estable ante perturbaciones de la carga, primero, un incremento de 250 Watts, y finalmente se retira la misma para dejar el generador en vacío.




Fig. 4.11 Respuesta de la frecuencia o velocidad de la maquina.




Fig. 4.12 Respuesta de la Fase del rotor.




Fig. 4.13 Salida del controlador frente a perturbaciones en la carga

Capítulo 5

Conclusiones y trabajo a futuro.

5.1 Conclusiones

En este trabajo de tesis se comprueba de manera experimental la eficacia en la estabilización y robustez frente a perturbaciones en la carga de un generador síncrono mediante un controlador óptimo inverso con estimador neuronal en tiempo real. Se observa la relativa facilidad de su implementación, sin engorrosos y tardados métodos de sintonización, ni exponiendo la máquina a posibles daños para lograr esto último.

Se observa como un modelo relativamente simple de estimador neuronal, cumple perfectamente con su objetivo, como el método de Gradiente de velocidad se puede implementar en un programa en tiempo real sin sacrificar significativamente el tiempo de ejecución.

5.2 Trabajo Futuro

Como trabajo a futuro se propone lo siguiente:

- Sustituir las interfaces de A-D por unas de mayor velocidad
- Realizar pruebas en tiempo real de seguimiento o tracking con otro tipo de señal
- Realizar los mismo experimentos con máquinas de mayor capacidad

Referencia Bibliográfica


- [1] A. Y. Alanis, F. Ornelas, and E. N. Sánchez. Discrete-time inverse optimal neural control for synchronous generators. *Engineering Applications of Artificial Intelligence*, 2012.
- [2] A. Y. Alanis, E. N. Sanchez, and A. G. Loukianov. Discrete time adaptive backstepping nonlinear control via high order neural networks. *IEEE Transactions on Neural Networks*, 18(4):1185–1195, 2007.
- [3] P. M. Anderson and A. A. Fouad. *Power System Control and Stability*. IEEE Press, New York, USA, 1994.
- [4] M. A. Arjona, R. Escarela-Perez, G. Espinosa-Perez, and J. Alvarez-Ramirez. Validity testing of third-order nonlinear models for synchronous generators. *Electric Power Systems Research*, 79:953–958, 2009.
- [5] V. H. Benítez Baltazar. *Decentralized continuous time neural control*. PhD thesis, Cinvestav, Unidad Guadalajara, 2010.
- [6] R. E. Bellman. *Dynamic Programming*. Princeton University Press., Princeton, NJ, USA, 1957.
- [7] R. E. Bellman and S. E. Dreyfus. *Applied Dynamic Programming*. Princeton University Press., Princeton, NJ, USA, 1962.
- [8] L. A. Feldkamp, T. M. Feldkamp, and D. V. Prokhorov. Neural network training with the nprkf. *Proceedings of International Joint Conference on Neural Networks*, 01:109–114. Res. Lab., Ford Motor Co., Dearborn, MI, 2001.
- [9] A. L. Fradkov and A. Y. Pogromsky. Introduction to control of oscillations and chaos. *World Scientific Publishing Co*, Singapore, 1998.
- [10] R. A. Freeman and P. V. Kokotovic. *Robust Nonlinear Control Design: State-Space and Lyapunov Techniques*. Birkhäuser, Cambridge, MA, USA, 1996.
- [11] R. Grover and P. Y. C. Hwang. *Introduction to Random Signals and Applied Kalman Filtering*. 2 edition, John Wiley and Sons., New York, USA, 1992.
- [12] S. Haykin. *Kalman Filtering and Neural Networks*. John Wiley and Sons., New York, USA, 2001.
- [13] Electric Power Research Institute. Power system dynamic analysis-phase i. *EPRI Report EL-484*, 1977.
- [14] M. Krstic and H. Deng. *Stabilization of Nonlinear Uncertain Systems*. Springer-Verlag., Berlin, Germany, 1998.
- [15] P. Kundur. *Power System Stability and Control*. McGraw-Hill, United states of America, 1994.
- [16] C. Leunga and L. Chan. Dual extended kalman filtering in recurrent neural networks. *Neural Networks*, 16:223–239, 2003.
- [17] F. Ornelas. *Inverse Optimal Control for Discrete-Time Nonlinear Systems*. PhD thesis, Cinvestav, Unidad Guadalajara, 2011.
- [18] L. S. Pontryagin, V. G. Boltyanskii, R. V. Gamkrelidze, and E. F. Mischenko. *The Mathematical Theory of Optimal Processes*. Interscience Publishers, New York, USA, 1962.
- [19] A. S. Poznyak, E. N. Sanchez, and W. Yu. Differential neural networks for robust nonlinear control. *Singapore: World Scientific*, 2001.

- [20] IEEE Comittee Report. *Recommended Phasor Diagram for Synchronous Machines*, volume PAS-88, pages 1593–1610. IEEE Transactions, 1969.
- [21] R. Sepulchre, M. Jankovic, and P. V. Kokotovic. *Constructive Nonlinear Control*. Springer-Verlag., Berlin, Germany, 1997.
- [22] Y. Song and J. W. Grizzle. The extended kalman filter as local asymptotic observer for discrete-time nonlinear systems. *Journal of Mathematical systems, Estimation and Control.*, 5(1):59–78, 1995.
- [23] ANSI/IEEE Standard. *IEEE Standar Dictionary of Electrical and Electronic Terms 100-1997*.
- [24] R. J. Williams and D. Zipser. A learning algorithm for continually runnig fully recurrent neural networks. *Neural Computation*, vol 1, pages 270-280, 1989.
- [25] J. A. Primbs, V. Nevistic, and J. C. Doyle, _Nonlinear optimal control: A control Lyapunov function and receding horizon perspective, _ Asian Journal of Control, vol. 1, pp.14_24, 1999.
- [26] R. A. Freeman and J. A. Primbs, _Control Lyapunov functions: New ideas from an old source, _ in Proceedings of the 35th IEEE Conference on Decision and Control , Kobe, Japan, Dec 1996, pp. 3926_3931.
- [27] V. M. Popov, *Hyperstability of Control Systems*. Berlin, Germany: Springer-Verlag, 1973.
- [28] J. C. Willems, _Dissipative dynamical systems: parts I and II, _ Archive for Rational Mechanics and Analysis, vol. 45, no. 5, pp. 321_351, 1972.
- [29] R. Ortega and M. W. Spong, _Adaptive motion control of rigid robots: a tutorial, _ Automatica, vol. 25, no. 6, pp. 877_888, 1989.
- [30] H. K. Khalil, *Nonlinear Systems*. Upper Saddle River, NJ, USA: Prentice-Hall, 1996.
- [31] D. Youla, L. Castriota, and H. Carlin, _Bounded real scattering matrices and the foundations of linear passive network theory, _ IRE Transactions on Circuit Theory, vol. 6, no. 1, pp. 102_124, 1959.
- [32] C. I. Byrnes, A. Isidori, and J. C. Willems, _Passivity, feedback equivalence, and the global stabilization of minimum phase nonlinear systems, _ IEEE Transactions on Automatic Control, vol. 36, pp. 1228_1240, 1991.
- [33] A. J. Van Der Schaft, *L2-Gain and Passivity Techniques in Nonlinear Control*. Berlin, Germany: Springer-Verlag, 1996.
- [34] R. Ortega, A. J. Van Der Schaft, I. Mareels, and B. Maschke, _Putting energy back in control, _ IEEE Control Systems Magazine, vol. 21, no. 2, pp. 18_33, 2001.
- [35] R. Ortega, A. Loría, P. J. Nicklasson, and H. Sira-Ramírez, *Passivity-based Control of Euler-Lagrange Systems: Mechanical, Electrical and Electromechanical Applications*. Berlin, Germany: Springer-Verlag, 1998.
- [36] C. I. Byrnes and W. Lin, _Losslessness, feedback equivalence, and the global stabilization of discrete-time nonlinear systems, _ IEEE Transactions on Automatic Control, vol. 39, no. 1, pp. 83_98, 1994.
- [37] S. Monaco and D. Normand-Cyrot, _Nonlinear representations and passivity conditions in discrete time, _ Lecture Notes in Control and Information Sciences, vol. 245, pp. 422_432, 1999.
- 102 BIBLIOGRAPHY
- [38] E. M. Navarro-López, _Dissipativity and passivity-related properties in nonlinear discrete-time systems, _ Ph.D. dissertation, Universitat Politècnica de Catalunya, Barcelona, Spain, June 2002.

- [39] D. S. Laila and A. Astol, Discrete-time IDA-PBC design for underactuated Hamiltonian control systems, in Proceedings of the 2006 American Control Conference, Minneapolis, Minnesota, USA, Jun 2006, pp. 188_193.
- [40] P. J. Moylan, Implications of passivity in a class of nonlinear systems, IEEE Transactions on Automatic Control, vol. 19, no. 4, pp. 373_381, 1974.
- [41] A. L. Fradkov and A. Y. Pogromsky, Introduction to Control of Oscillations and Chaos. Singapore: World Scientific Publishing Co., 1998.
- [42] E. M. Navarro-López, Local feedback passivation of nonlinear discrete-time systems through the speed-gradient algorithm, Automatica, vol. 43, no. 7, pp. 1302_1306, 2007.
- [43] R. Gourdeau, Object-oriented programming for robotic manipulator simulation, IEEE Robotics and Automation, vol. 4, no. 3, pp. 21_29, 1997.
- [44] G. A. Rovithakis and M. A. Christodoulou, Adaptive Control with Recurrent High-Order Neural Networks. Berlin, Germany: Springer-Verlag, 2000.
- [45] E. N. Sanchez, L. J. Ricalde, R. Langari, and D. Shahmirzadi, Rollover prediction and control in heavy vehicles via recurrent neural networks, Intelligent Automation and Soft Computing, vol. 17, no. 1, pp. 95_107, 2011.
- [46] E. N. Sanchez, A. Y. Alanis, and A. G. Loukianov, Discrete-time High Order Neural Control. Berlin, Germany: Springer-Verlag, 2008.
- [47] A. S. Posnyak, E. N. Sanchez, and W. Yu, Differential Neural Networks for Robust Nonlinear Control. USA: World Scientific, 2000.
- [48] J. W. Curtis and R. W. Beard, A complete parameterization of CLF-based input-to-state stabilizing control laws, International Journal of Robust and Nonlinear Control, vol. 14, pp. 1393_1420, 2004.
- [49] R. A. Freeman and P. V. Kokotović, Inverse optimality in robust stabilization, SIAM Journal on Control and Optimization, vol. 34, no. 4, pp. 1365_1391, 1996.
- [50] J. A. Primbs, Nonlinear optimal control: A receding horizon approach, Ph.D. dissertation, California Institute of Technology, Pasadena, CA, USA, January 1999.
- [51] R. E. Bellman, Mathematical Optimization Techniques. USA: The RAND Corporation, 1963.
- [52] D. E. Kirk, Optimal Control Theory: An Introduction. Englewood Cliffs, NJ, USA: Prentice-Hall, 1970.
- [53] A. Al-Tamimi and F. L. Lewis, Discrete-time nonlinear HJB solution using approximate dynamic programming: Convergence proof, IEEE Transactions on Systems, Man, Cybernetics-Part B, vol. 38, no. 4, pp. 943_949, 2008.
- [54] F. L. Lewis and V. L. Syrmos, Optimal Control. New York, NY, USA: John Wiley & Sons, 1995.
- [55] T. Basar and G. J. Olsder, Dynamic Noncooperative Game Theory, 2nd ed. New York, NY, USA: Academic Press, 1995.
- [56] T. Ohsawa, A. M. Bloch, and M. Leok, Discrete Hamilton-Jacobi theory and discrete optimal control, in Proceedings of the 49th IEEE Conference on Decision and Control (CDC), Dec 2010, pp. 5438_5443.
- [57] W. M. Haddad, V.-S. Chellaboina, J. L. Fausz, and C. Abdallah, Optimal discrete-time control for non-linear cascade systems, Journal of The Franklin Institute, vol. 335, no. 5, pp. 827_839, 1998.

- [58] J. P. LaSalle, *The Stability and Control of Discrete Processes*. Berlin, Germany: Springer-Verlag, 1986.
- [59] M. Vidyasagar, *Nonlinear Systems Analysis*, 2nd ed. Englewood Cliffs, NJ, USA: Prentice-Hall, 1993.
- [60] G. L. Amicucci, S. Monaco, and D. Normand-Cyrot, *Control Lyapunov stabilization of a class of discrete-time systems*, in *Proceedings of the 36th IEEE Conference on Decision and Control*, vol. 1, San Diego, CA, USA, Dec 1997, pp. 923–924.
- [61] C. M. Kellett and A. R. Teel, *Results on discrete-time control-Lyapunov functions*, in *Proceedings of the 42nd IEEE Conference on Decision and Control*, 2003, vol. 6, Maui, Hawaii, USA, Dec 2003, pp. 5961–5966.
- [62] Z. Artstein, *Stabilization with relaxed controls*, *Nonlinear Analysis: Theory, Methods and Applications*, vol. 7, no. 11, pp. 1163–1173, 1983.
- [63] C. Cruz-Hernandez, J. Alvarez-Gallegos, and R. Castro-Linares, *Stability of discrete nonlinear systems under nonvanishing perturbations: application to a nonlinear model matching problem*, *IMA Journal of Mathematical Control & Information*, vol. 16, pp. 23–41, 1999.
- [64] Z. P. Jiang, E. D. Sontag, and Y. Wang, *Input-to-state stability for discrete-time nonlinear systems*, *Automatica*, vol. 37, pp. 857–869, 1999.
- [65] E. D. Sontag, *On the input-to-state stability property*, *Systems & Control Letters*, vol. 24, pp. 351–359, 1995.
- [66] L. Magni and R. Scattolini, *Assessment and Future Directions of Nonlinear Model Predictive Control*, ser. *Lecture Notes in Control and Information Sciences*. Berlin, Germany: Springer-Verlag, 2007, vol. 358.
- [67] M. Krstić and Z. Li, *Inverse optimal design of input-to-state stabilizing nonlinear controllers*, *IEEE Transactions on Automatic Control*, vol. 43, no. 3, pp. 336–350, 1998.
- [68] P. O. M. Scokaert, J. B. Rawlings, and E. S. Meadows, *Discrete-time stability with perturbations: application to model predictive control*, *Automatica*, vol. 33, no. 3, pp. 463–470, 1997.
- [69] B. Brogliato, R. Lozano, B. Maschke, and O. Egeland, *Dissipative Systems Analysis and Control: Theory and Applications*, 2nd ed. Berlin, Germany: Springer-Verlag, 2007.
- [70] B. Castillo-Toledo, S. D. Gennaro, A. G. Loukianov, and J. Rivera, *Discrete time sliding mode control with application to induction motors*, *Automatica*, vol. 44, no. 12, pp. 3036–3045, 2008.
- [71] F. Ornelas, A. G. Loukianov, E. N. Sanchez, and E. J. Bayro, *Planar robot robust decentralized neural control*, in *Proceedings of the IEEE Multi-conference on Systems and Control (MSC 2008)*, San Antonio, Texas, USA, Sep 2008.
- [72] E. N. Sanchez and A. Y. Alanis, *Redes Neuronales: Conceptos Fundamentales y Aplicaciones a Control Automático*. España: Pearson Education, 2006.
- [73] W. Lin and C. I. Byrnes, *Passivity and absolute stabilization of a class of discrete-time nonlinear systems*, *Automatica*, vol. 31, no. 2, pp. 263–267, 1995.
- [74] M. Margaliot and G. Langholz, *Some nonlinear optimal control problems with closedform solutions*, *International Journal of Robust and Nonlinear Control*, vol. 11, no. 14, pp. 1365–1374, 2001.

- [75] A. G. Loukianov, _Nonlinear block control with sliding modes, _ Automation and Remote Control, vol. 57, no. 7, pp. 916_933, 1998.
- [76] W. Lin and C. I. Byrnes, _Design of discrete-time nonlinear control systems via smoothfeedback, _ IEEE Transaction on Automatic Control, vol. 39, no. 11, pp. 2340_2346,1994.



**CENTRO DE INVESTIGACIÓN Y DE ESTUDIOS AVANZADOS DEL I.P.N.
UNIDAD GUADALAJARA**

El Jurado designado por la Unidad Guadalajara del Centro de Investigación y de Estudios Avanzados del Instituto Politécnico Nacional aprobó la tesis

Control Optimo Inverso en Tiempo Real para Generador Sincrono

del (la) C.

José Roberto ROBLES RODRÍGUEZ

el día 27 de Septiembre de 2013.

Dr. Edgar Nelson Sánchez Camperos
Investigador CINVESTAV 3D
CINVESTAV Unidad Guadalajara

Dr. Alexander Georgievich Loukianov
Investigador CINVESTAV 3C
CINVESTAV Unidad Guadalajara

Dr. Antonio Ramírez Treviño
Investigador CINVESTAV 3A
CINVESTAV Unidad Guadalajara



CINVESTAV - IPN
Biblioteca Central



SSIT0011910