

## Estabilizador de Sistemas de Potencia usando Control Predictivo basado en Modelo

Manuel A. Duarte-Mermoud<sup>a,b,\*</sup>, Freddy Milla<sup>b</sup>

<sup>a</sup> Departamento de Ingeniería Eléctrica, Facultad de Ciencias Físicas y Matemáticas, Universidad de Chile, Av. Tupper 2007, Santiago, Chile.

<sup>b</sup> Centro Avanzado de Tecnología para la Minería (AMTC), Facultad de Ciencias Físicas y Matemáticas, Universidad de Chile, Av. Beauchef 850, Santiago, Chile.

---

### Resumen

Se propone un estabilizador de potencia predictivo para amortiguar oscilaciones de potencia en un sistema eléctrico de potencia (SEP) formado por una sola máquina conectada a una barra infinita (Single Machine Infinite Bus, SMIB). Este enfoque considera un análisis de estabilidad de pequeña señal, usando un modelo incremental alrededor de un punto de operación. El estabilizador proporciona señales de control óptimas, debido a que además de utilizar el controlador predictivo basado en modelo (Model Predictive Controller, MPC) sus parámetros se optimizan fuera de línea empleando un algoritmo de optimización por enjambre de partículas (Particle Swarm Optimization, PSO). Su comportamiento se compara con un estabilizador del sistema potencia convencional, con parámetros también optimizados con PSO fuera de línea. Para validar la metodología propuesta, se presentan numerosas simulaciones de respuestas dinámicas del SMIB, para diferentes condiciones de operación y perturbaciones.

### Palabras Clave:

Sistemas eléctricos y electrónicos de potencia, Estabilizador de sistemas de potencia (PSS), Estabilizador predictivo de sistemas de potencia (PPSS), Control predictivo basado en modelo (MPC), Optimización por enjambre de partículas (PSO), Simulación de sistemas.

### Power System Stabilizer based on Model Predictive Control

### Abstract

A model predictive power system stabilizer is proposed in this paper to damp power oscillations in an electric power system (EPS). The design of the stabilizer is optimal in the sense that its parameters are determined by using off-line particle swarm optimization (PSO) technique. The proposed methodology is applied to an EPS composed by a single machine connected to an infinite bus (SMIB). The analysis is performed through a small signal stability analysis, deriving incremental equations linearized around an operating point. The results obtained by the proposed method are compared with a conventional power system stabilizer, also optimized by PSO. Through numerous computer simulations under different operating conditions and perturbations on the SMIB, it was possible to establish some advantages of the proposed technique as compared with the conventional technique.

### Keywords:

Electrical and electronics power systems, Power system stabilizer (PSS), Predictive power system stabilizer (PPSS), Model predictive control (MPC), Particle swarm optimization (PSO), Simulation systems.

---

\*Autor para la correspondencia: mduartem@ing.uchile.cl

## 1. Introducción

Los sistemas eléctricos de potencia (SEP) son sistemas no lineales complejos, que a menudo presentan oscilaciones electromecánicas de baja frecuencia debido a un amortiguamiento insuficiente, causadas por condiciones de operación adversas. Optimizar el amortiguamiento de las oscilaciones de baja frecuencia es un problema crítico en los SEP, para lo cual se utilizan estabilizadores de sistemas de potencia (Power System Stabilizers, PSS) para amortiguar estas oscilaciones y mejorar la estabilidad del sistema. En (Karnik et al., 2009) se reporta la sintonización de parámetros del PSS, para lograr una respuesta satisfactoria del sistema de potencia en una amplia gama de condiciones de operación, utilizando una técnica de optimización robusta y eficiente, esto es, se presenta un novedoso concepto de integrar el principio de diseño Taguchi robusto con optimización por enjambre de partículas (Particle Swarm Optimization, PSO) para el diseño del PSS. El enfoque propuesto emplea la relación señal/ruido y conceptos de matriz ortogonal del diseño de Taguchi, para determinar el ajuste óptimo robusto de los parámetros del PSS usando PSO.

La robustez del PSS diseñado se verifica mediante el análisis de varianza. Además, la eficacia del PSS robusto se ilustra mediante simulaciones en el dominio del tiempo, ya que se aplica a una sola máquina conectada a una barra infinita (Single Machine Infinite Bus, SMIB), para una amplia gama de condiciones de carga y perturbaciones.

En (Kahl and Leibfried, 2013) se presenta una estrategia integral de control que considera la información de las medidas de fase de las unidades para amortiguar las oscilaciones inter-área. El método de control predictivo descentralizado empleado, tiene una unidad de control para cada dispositivo controlable, tales como los sistemas de transmisión de corriente alterna flexible (Flexible AC Transmission Systems, FACTS), o los sistemas de transporte de energía eléctrica utilizado en largas distancias (High Voltage Direct Current, HVDC) y coordina su comportamiento después de una falla. Sin embargo, ya que el sistema se expresa en términos de variaciones, es necesario añadir el comportamiento de la variación del ángulo de tensión debido a que la convergencia de la variación de frecuencia a cero no garantiza la convergencia de la variación del ángulo a cero.

En (Shahriar et al., 2012), un controlador predictivo basado en modelo (Model Predictive Controller, MPC) se diseña como una solución para mejorar las oscilaciones en un sistema formado por una sola máquina conectada a una barra infinita (Single Machine Infinite Bus, SMIB) conectado con un dispositivo FACTS, denominado controlador de flujo de potencia unificado (Unified Power Flow Controller, UPFC). El UPFC se utiliza principalmente en los sistemas de transmisión que pueden controlar el flujo de energía mediante el control de la magnitud de la tensión, el ángulo de fase y la impedancia. Además, como el MPC no sólo proporciona entradas de control óptimas, sino que también predice las salidas del modelo del sistema, le permite alcanzar el objetivo deseado. Por lo tanto, una combinación de UPFC y MPC, junto con los parámetros de un modelo adecuado del sistema, puede proporcionar un rendimiento satisfactorio para amortiguar las oscilaciones del sistema preservando la estabilidad del sistema. Sin embargo, aunque

la propuesta es interesante, los resultados no se presentan con el rigor adecuado.

En (Phulpin et al., 2011), se analiza el problema de controlar un HVDC utilizando información en tiempo real para evitar el fenómeno de la pérdida de sincronismo en los sistemas de energía. Los autores proponen una estrategia de control de tiempo discreto basada en MPC, la cual resuelve un problema de control óptimo de lazo abierto en cada intervalo de tiempo, realizando una búsqueda en un árbol de eventos. Se comparan varios criterios de optimización basados en índices de estabilidad transitorios. El documento presenta resultados de simulación para dos sistemas de referencia con 9 y 24 barras, respectivamente, y un enlace HVDC integrado. Los resultados muestran que la estrategia de control logra la modulación del flujo de potencia del HVDC, lo que mejora significativamente la capacidad del sistema para mantener el sincronismo producto de una gran perturbación. En (Sebaa et al., 2012) se presenta un MPC para mejorar la estabilidad transitoria del sistema de energía. En concreto, el documento se centra en la aplicación de la técnica MPC para regular la potencia de salida de los generadores cuando el sistema está sujeto a fallas y perturbaciones. La aplicación en un sistema SMIB equipado con un condensador en serie controlado por tiristor (Thyristor Controlled Series Capacitor, TCSC) se lleva a cabo para mostrar las ventajas de la técnica propuesta.

En (Ford et al., 2008) se realiza un enfoque de MPC no lineal, para proporcionar protección para la estabilidad de primera oscilación de líneas de transmisión de un SEP vulnerable (estabilidad transitoria). Los autores consideran grandes eventos perturbativos y se centran en evitar la primera separación angular de oscilación utilizando dispositivos FACTS. La estrategia de control presentada en (Ford et al., 2008) para los dispositivos FACTS, está diseñada para ser numéricamente eficiente (debido a los cortos horizontes del MPC) y robusta (contra complicados mecanismos de separación). Los estudios de simulación llevados a cabo en un sistema de tres máquinas ilustran que el enfoque MPC propuesto alcanza un buen comportamiento ante una gran primera perturbación, próxima a los controladores de estabilidad transitoria existentes. Además, se muestra que el enfoque de control que se propone mejora los tiempos críticos de despeje y mejora la capacidad de transferencia en los estudios de simulación en el sistema de 39 barras de Nueva Inglaterra. (Ford et al., 2008).

En (Rajkumar and Mohler, 1994) se presenta un marco para el desarrollo de un MPC no lineal de tiempo discreto utilizando TCSC y mediciones fasoriales de magnitud y ángulo del voltaje de la barra para la estabilización y amortiguamiento rápido de sistemas de potencia multi-máquinas, que están sujetos a grandes perturbaciones. Cuando las fallas son grandes, el MPC no lineal se utiliza para devolver el estado del sistema de potencia a una región pequeña cerca del equilibrio post-falla. Los resultados de la simulación se realizan en un sistema de alimentación de cuatro máquinas.

En (Chatterjee et al., 2011), la optimización por enjambre de hormigas caótico (Chaotic Ant Swarm Optimization, CASO) se utiliza para ajustar los parámetros de un PSS de una entrada y de doble entrada. Este algoritmo explora el comportamiento caótico y la auto-organización de las hormigas en el proceso de búsqueda. Al comparar el CASO con la optimización por enjambre de partículas (PSO) o por

algoritmos genéticos (AG), se verifica que CASO es más eficaz que los demás algoritmos para encontrar el rendimiento óptimo transitorio de un PSS y un regulador automático de voltaje (Automatic Voltage Regulator, AVR) equipado con una única máquina y sistema de barra infinita.

Por último, en (Wang et al., 2009) se propone un nuevo control de excitación del generador, para asegurar la estabilidad de un SEP con múltiples generadores. El algoritmo MPC se implementa utilizando un DSP (Digital Signal Processor) para lograr la estabilidad en tiempo real con una velocidad adecuada. Las simulaciones muestran que la oscilación inter-área que surge después de una gran perturbación en una línea de conexión de dos áreas, se puede amortiguar rápidamente. Además, la simulación muestra que la estabilidad del MPC para múltiples generadores, tiene una calidad similar en comparación con el control de excitación óptima utilizando un AVR de alta ganancia, además de un PSS sintonizado finamente.

En cambio, en este trabajo se propone un estabilizador de potencia predictivo basado en modelo (Model Predictive Power System Stabilizer, MPPSS) para amortiguar las oscilaciones de potencia en un sistema SMIB, el cual entrega señales de control optimizadas fuera de línea mediante la técnica PSO. El enfoque considera un análisis de estabilidad de pequeña señal, y se compara con un estabilizador de sistema potencia convencional (Conventional Power System Stabilizer, CPSS), también optimizado con PSO. Numerosas simulaciones de respuestas dinámicas del sistema SMIB para diferentes condiciones de operación (niveles de potencia, perturbaciones sobre diferentes variables del sistema y variación de la estructura del sistema) se presentan para validar la metodología propuesta.

El artículo está organizado de modo que en la Sección II se introducen los conceptos básicos que soportan el trabajo; el MPC, CPSS y PSO. En la Sección III, se presenta en detalle el enfoque propuesto para el diseño del MPPSS. En las Secciones IV y V se presentan ejemplos de simulaciones, algunas ya presentadas en (Duarte-Mermoud and Milla, 2016) y otras adicionales, que permiten apreciar las ventajas del método propuesto. En la Sección V se comenta sobre la estabilidad del controlador y finalmente, en la Sección VI se presentan las principales conclusiones del trabajo realizado.

**2. Conceptos Básicos sobre MPC, CPSS y PSO**

A continuación se presenta una breve descripción de los principios matemáticos y físicos en que se basan los controladores MPC y CPSS, además de una pequeña descripción de la técnica PSO.

**2.1. Control Predictivo Basado en Modelo (MPC)**

El control predictivo basado en modelo es una técnica de control basada en la información pasada y presente, usada para predecir el comportamiento futuro de un sistema, a través del uso explícito de un modelo del proceso. La generación de la señal de control se realiza mediante la minimización de una función objetivo (FO). Esencialmente, esta técnica se basa en el concepto de control de horizonte móvil, que implica el cálculo de la secuencia de control para todo el horizonte de predicción, pero sólo la primera señal de control de la secuencia se aplica a la planta. Este proceso se repite en los siguientes instantes de muestreo (Camacho and Bordons, 2007).

El MPC es una de las pocas técnicas de control que permiten

la incorporación de restricciones sobre las variables del sistema en la formulación del problema de control. Además, esta estrategia de control es válida para una amplia gama de sistemas, lineales y no lineales, y ha tenido un impacto significativo en la industria. (Del Re, et al., 2010), (Ocampo-Martínez, et al., 2010), (Zheng, 2011).

Con respecto a la garantía de estabilidad del sistema de lazo cerrado, este es un aspecto esencial del diseño de un controlador en general y del MPC en particular (Mayne et al., 2000). Las condiciones de estabilidad se basan en una formulación del controlador que incluye el costo terminal así como las restricciones terminales.

Las aplicaciones del MPC en los SEP con respeto al problema de oscilaciones de potencia descritas en (Kundur, 1994) ya fueron discutidas en la sección anterior en (Shahriar et al., 2012), (Phulpin and Hazra, 2011), (Sebaa et al., 2012), (Ford et al., 2008), (Rajkumar and Mohler, 1994) y (Wang et al., 2009).

**2.2. PSS Convencional (CPSS)**

Un PSS práctico debe ser robusto en una amplia gama de condiciones de funcionamiento y capaz de amortiguar los modos de oscilación del sistema de potencia. En este trabajo se analiza el CPSS como un enfoque de diseño único basado en un modelo lineal de un sistema SMIB en la condición de funcionamiento normal. El sistema SMIB clásico (Kundur, 1994) se presenta en la Figura 1.

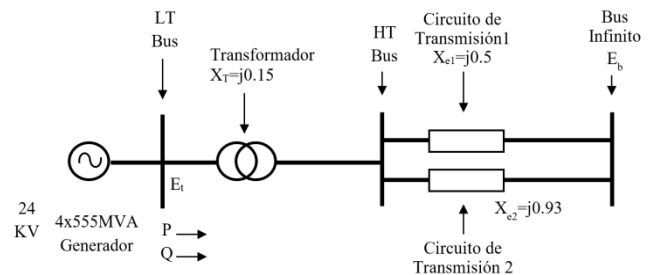


Figura 1: Sistema de prueba máquina-barra infinita (SMIB).

La finalidad del PSS es introducir una componente de torque amortiguante. La desviación de velocidad se utiliza como señal lógica para controlar la excitación del generador del CPSS.

El diagrama de bloques del sistema SMIB con AVR, un tiristor de alta ganancia de excitación, un generador síncrono y el CPSS se muestra en la Figura 2. El generador, incluyendo el AVR, el sistema de excitación y la reactancia del circuito de transmisión, está representados por un modelo de dos ejes de cuarto orden (Ver ecuación (1)).




Figura 2: Representación en diagrama de bloques del sistema SMIB, con AVR, excitador de alta ganancia de tiristor, generador síncrono y CPSS.

Para el estudio se considerará el modelo IEEE tipo ST1A (IEEE, 2005) del sistema de excitación estática mostrada en la Figura 2, donde  $\Delta\omega_r$ ,  $\Delta\delta$  y  $\Delta\psi_{fd}$  representan la desviación de velocidad, la desviación del ángulo del rotor y la desviación del flujo de campo, respectivamente (ver Figura 2).  $\Delta E_{fd}$ ,  $\Delta T_e$  y  $\Delta T_m$  representan, la desviación de la tensión de campo, la desviación del par eléctrico y la desviación del par mecánico, respectivamente (ver Figura 2).  $\Delta V_s$ ,  $\Delta V_1$ ,  $\Delta V_{ref}$  y  $\Delta E_t$  representan la desviación de voltaje del CPSS, la desviación de la tensión del transductor, la desviación de la tensión de referencia y la desviación de la tensión en bornes del generador, respectivamente (ver Figura 2).  $G_{ex}(s)$  es la función de transferencia entre el AVR y el excitador, que para un excitador de tiristor tiene la forma  $G_{ex}(s)=K_A$ . Finalmente  $K_A$ ,  $K_1, \dots, K_6$ ,  $H$ ,  $K_D$ ,  $T_3$ ,  $T_R$  y  $\omega_0$  son los parámetros del sistema. Para una explicación más detallada de sistema y sus parámetros ver (Kundur, 1994).

El PSS se ha utilizado ampliamente para mejorar la estabilidad general de grandes sistemas de potencia (Shahriar et al., 2012). El CPSS considerado aquí, es la red convencional de atraso y adelanto de fase con ganancia  $K_s$  y constantes de tiempo de retardo y de avance  $T_1$ ,  $T_2$ , respectivamente y constante de tiempo de rechazo  $T_w$ , la que se utiliza para eliminar las señales de corriente continua (CC). Sin ella, los cambios de velocidad en estado estacionario modificarían el voltaje en bornes del generador. El CPSS se muestra en detalle en la Figura 3.




Figura 3: Diagrama en bloques del sistema CPSS.

2.3. Optimización por Enjambre de Partículas (PSO)

La técnica PSO emula el comportamiento que posee una bandada de pájaros o un cardumen de peces que evolucionan en el tiempo de acuerdo a ciertas reglas. PSO es un método de optimización dentro de los llamados Algoritmos Evolutivos (AE) que se encarga de hacer evolucionar una población de partículas a medida que transcurren diversas generaciones con el objetivo de encontrar la mejor solución global para el problema que ellas representan. Sin embargo, a diferencia de otros EAs, PSO no implementa operadores de mutación o cruzamiento, y desde su versión básica siempre mantiene lo mejor de su experiencia evolutiva. Como la idea es simular el movimiento de partículas en un espacio D-dimensional, donde D está dado por el número de incógnitas del problema original, entonces se necesitan fórmulas básicas que permitan actualizar tanto la velocidad como la posición dentro de ese espacio. En PSO, cada partícula representa una posible solución al problema de optimización (Kennedy and Eberhart, 2001), cada una de las cuales tiene asociado un valor de la función fitness, la cual se desea optimizar. Si el espacio de búsqueda de la solución óptima es D-dimensional, entonces la *i*-ésima partícula de la población (N en total) se representa por su posición y su velocidad en cada instante de tiempo (iteración) las cuales van cambiando de acuerdo a ciertas reglas. En el algoritmo básico de PSO (Eberhart and Kennedy, 1995a,b), éstas se hacen evolucionar de acuerdo a las siguientes relaciones.

$$v_{id}(k+1) = v_{id}(k) + c_1 r_1(k)(p_{id}(k) - x_{id}(k)) + c_2 r_2(k)(g_d - x_{id}(k))$$

$$x_{id}(k+1) = x_{id}(k) + v_{id}(k+1)$$

en las cuales  $v_{id}$  y  $x_{id}$  representan la velocidad y la posición de la partícula *i* en su dimensión *d*, respectivamente, todo esto en la generación (iteración) *k*, donde  $d \in \{1, 2, \dots, D\}$ ,  $i \in \{1, 2, \dots, N\}$  y  $k \in \{1, \dots, k_{max}\}$ . Las constantes  $c_1$  y  $c_2$  representan la aceleración cognitiva y la aceleración social, y determinan la influencia de la experiencia individual y grupal, respectivamente, sobre el desempeño de cada partícula. Los términos  $r_1(k)$  y  $r_2(k)$  son un par de números aleatorios uniformemente distribuidos en el rango [0,1] usados para recrear el componente estocástico que presenta toda población en un enjambre.  $p_{id}(k)$  es una variable que lleva la cuenta de la mejor posición de la *i*-ésima partícula en su dimensión *d*, y a su vez  $g_d(k)$  lleva cuenta de la mejor posición global de las partículas en su dimensión *d*.

En sus versiones posteriores más comúnmente usadas, debido a las mejoras que conlleva y cierta facilidad para los análisis de estabilidad, aparece la versión con *peso de inercia* (Shi and Eberhart, 1998), también conocida como PSOiw (inercia weight) o PSOW (weighted), que incluye el parámetro de inercia  $\omega$  en la ecuación de actualización de velocidad de la forma

$$v_{id}(k+1) = \omega v_{id}(k) + c_1 r_1(k)(p_{id}(k) - x_{id}(k)) + c_2 r_2(k)(g_d - x_{id}(k))$$

donde  $\omega \in [0,1]$  sirve básicamente para contribuir a la convergencia de las partículas. Otra de las versiones extendidas de la versión estándar es PSO con *factor de restricción* (Clerc, 1999), también conocido como PSOcf (constriction factor) o PSOc (constricted), que incorpora un factor multiplicativo  $\omega$  común para la velocidad de las partículas de la forma

$$v_{id}(k+1) = \varphi(v_{id}(k) + c_1 r_1(k)(p_{id}(k) - x_{id}(k)) + c_2 r_2(k)(g_d - x_{id}(k)))$$

aportando a la convergencia al limitar el crecimiento de la velocidad. Una comparación entre PSOiw y PSOcf se puede encontrar en (Eberhart and Shi, 2000).

Existen diferentes maneras de inicializar las posiciones y velocidades de las partículas. Algunas de ellas y su impacto en el comportamiento del algoritmo se discuten en (Carlisle and Dozier, 2001). También, esta elección inicial tiene influencia en la convergencia del algoritmo, lo cual ha sido tratado en (Cazzaniga, et al., 2015) mostrando que elecciones logarítmicas, normales y lognormales son superiores a la elección uniforme. Como una forma de comprar las diferentes versiones de PSO se han desarrollado una serie de test que permiten probar las bondades de nuevos esquemas (Bratton and Kennedy, 2007), (Zambrano-Bigiarini et al., 2011). Otras propiedades como convergencia y estabilidad también han sido bien estudiadas, ver por ejemplo (Clerc and Kennedy, 2002).

Para el proceso de optimización, los parámetros y condiciones del algoritmo utilizados en este artículo fueron determinados a través de un set de simulaciones de prueba y corresponden a los siguientes:

- Población inicial 150 partículas de búsqueda.
- Factor de inercia variable con  $\omega_{max} = 1,9$  y  $\omega_{min} = 0,4$ .
- Constantes de aceleración  $c_1 = 2$ ,  $c_2 = 2$ .
- Número máximo de iteraciones 1000.
- Tiempo de simulación  $t_f = 75[s]$ .



### 3. Diseño MPPSS y CPSS para un Sistema SMIB

En esta sección presentamos la metodología propuesta para la estabilización de potencia en un sistema SMIB, la que incluye el diseño del MPPSS y el diseño del CPSS optimizados para amortiguar los modos de oscilación en un sistema SMIB, incluyendo las restricciones y el problema de optimización.

#### 3.1. Diseño del MPPSS

La estrategia de control propuesta en este trabajo se basa en un algoritmo MPC, que determina el punto de ajuste óptimo para amortiguar los modos de oscilación en un sistema SMIB. El MPC optimiza dinámicamente una función objetivo general incluyendo restricciones de igualdad y desigualdad. Entonces, el problema descrito puede ser resuelto analíticamente con la teoría de control predictivo, mediante algoritmos numéricos, cuando se trabaja con restricciones (Wang et al., 2009).

Matemáticamente el sistema SMIB se puede representar como el sistema dinámico (1)

$$\begin{bmatrix} \Delta \dot{\omega}_r(t) \\ \Delta \dot{\delta}(t) \\ \Delta \dot{\Psi}_{fd}(t) \\ \Delta \dot{V}_1(t) \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} & a_{13} & 0 \\ a_{21} & 0 & 0 & 0 \\ 0 & a_{32} & a_{33} & a_{34} \\ 0 & a_{42} & a_{43} & a_{44} \end{bmatrix} \begin{bmatrix} \Delta \omega_r(t) \\ \Delta \delta(t) \\ \Delta \Psi_{fd}(t) \\ \Delta V_1(t) \end{bmatrix} + \begin{bmatrix} b_{11} & 0 \\ 0 & 0 \\ 0 & b_{32} \\ 0 & 0 \end{bmatrix} \begin{bmatrix} \Delta T_m(t) \\ \Delta V_s(t) \end{bmatrix} \quad (1)$$

donde  $a_{ij}$  con  $i, j = 1, \dots, 4$  son los parámetros del sistema SMIB (Kundur, 1994). Definiendo el vector de estado como  $x(t) = [\Delta \omega_r(t) \ \Delta \delta(t) \ \Delta \Psi_{fd}(t) \ \Delta V_1(t)]^T \in \mathfrak{R}^4$ , la variable de control como  $u(t) = [\Delta T_m(t) \ \Delta V_s(t)]^T \in \mathfrak{R}^2$  y las matrices,

$$A_c = \begin{bmatrix} a_{11} & a_{12} & a_{13} & 0 \\ a_{21} & 0 & 0 & 0 \\ 0 & a_{32} & a_{33} & a_{34} \\ 0 & a_{42} & a_{43} & a_{44} \end{bmatrix} \in \mathfrak{R}^{4 \times 4} \quad B_c = \begin{bmatrix} b_{11} & 0 \\ 0 & 0 \\ 0 & b_{32} \\ 0 & 0 \end{bmatrix} \in \mathfrak{R}^4$$

donde  $B_{c1} \in \mathfrak{R}^2$  y  $B_{c2} \in \mathfrak{R}^2$  son, respectivamente, la primera y la segunda columna de la matriz  $B_c$ . El sistema (1) se puede representar en forma resumida como se muestra en (2).

La Figura 4 muestra como el MPPSS proporciona la señal de control  $\Delta V_s(t)$  basada en la optimización de la función objetivo  $J$  (ver (5)), donde la variable controlada  $x(t)$  debe converger al origen. El sistema dinámico utilizado para representar el sistema SMIB, así como el control MPPSS, son afectados por variaciones en el tiempo de la potencia activa  $P$  (ver Figura 4).




Figura 4: Sistema SMIB con MPPSS.

El modelo continuo y el modelo discreto del sistema con tiempo de muestreo  $T_s$  se presentan en (2) y (3), respectivamente,

$$\dot{x}(t) = A_c x(t) + B_c(t)u(t) \quad (2)$$

$$x(k+1) = A_d x(k) + B_d(k)u(k) \quad (3)$$

con  $A_d(T_s) = e^{A_c T_s} \in \mathfrak{R}^{4 \times 4}$  y  $B_d(T_s) = (e^{A_c T_s} - I)A_c^{-1}B_c \in \mathfrak{R}^{4 \times 2}$ .

El modelo predictivo puede ser escrito como,

$$x(k+1) = A_d x(k) + B_{d1} \Delta T_m(k) + B_{d2} \Delta V_s(k) \quad (4)$$

donde  $B_{d1} \in \mathfrak{R}^2$  y  $B_{d2} \in \mathfrak{R}^2$  son la primera y segunda columnas de la matriz  $B_d$ , respectivamente.

La variable de control es  $\Delta V_s(k)$  mientras que  $\Delta T_m(k)$  puede estimarse a partir de un modelo basado en datos reales. En nuestro caso  $\Delta T_m(k)$  se considera constante e igual a cero, porque en el modelo no hay control de frecuencia primario o secundario.

El amortiguamiento de los modos de oscilación en el sistema SMIB por el algoritmo MPC, implica resolver el problema de optimización (5) para encontrar el conjunto óptimo  $\{\Delta V_s^*(k), \dots, \Delta V_s^*(k+N_p-1)\}$  de acciones de control a  $N_p$  pasos y aplicar la señal única  $\Delta V_s^*(k)$  como acción de control en el instante  $k$ . El problema puede entonces plantearse como

$$\min_{\{\Delta V_s^*(k), \dots, \Delta V_s^*(k+N_p-1)\}} J = \sum_{j=1}^{N_p} x(k+j)' R x(k+j) + \lambda \Delta V_s^*(k+j-1)^2 \quad (5)$$

(donde  $R \in \mathfrak{R}^{4 \times 4}$  es una matriz de ponderación positiva definida para el estado del sistema, que en este estudio se considera diagonal, y  $\lambda$  es un escalar que pondera la señal de control) sujeto a,

$$x(k+1) = A_d x(k) + B_{d1} \Delta T_m(k) + B_{d2} \Delta V_s(k)$$

⋮

$$x(k+N_p) = A_d x(k+N_p-1) + B_{d1} \Delta T_m(k+N_p-1) + B_{d2} \Delta V_s(k+N_p-1)$$

$$-1[p.u.] \leq \Delta V_s(k+j) \leq 10^{-3}[p.u.] \text{ para } j = 1, \dots, N_p$$

La solución del problema descrito anteriormente se obtiene mediante el algoritmo de programación cuadrática de MATLAB, de tal manera que el tiempo de muestreo no exceda el tiempo de cálculo de la acción de control, que es 0,1 [s]. Por otro lado, cabe consignar que el horizonte de predicción utilizado fue de 10 (1 [s]). Entonces, para hacer una búsqueda inteligente de los parámetros, se propone una segunda optimización del problema, esto es en una capa superior cuyo objetivo es la viabilidad del primer problema. La solución a este segundo problema es mediante un proceso de optimización con el algoritmo PSO (algoritmo de búsqueda meta heurístico el cual no puede asegurar un óptimo global). Estos valores son clave para resolver el problema de optimización, para cada uno de los escenarios estudiados. Luego, es posible construir una curva de Pareto para los diferentes valores de  $R$  y  $\lambda$ . Sin embargo, no todos estos puntos de la curva Pareto, garantizan la existencia de la solución del primer problema de optimización MPC en menos de 0,1 segundos. Por ello se seleccionó un par de valores de  $R$  y  $\lambda$ , que ante un número amplio de pruebas experimentales, probaron garantizar el tiempo de 0,1[s] para la solución.

Dejamos como trabajo futuro el análisis experimental de otros puntos factibles para nuestro problema de optimización sobre la curva de Pareto.

El análisis de estabilidad y robustez del controlador se puede realizar agregando más restricciones, obteniendo una solución del problema de optimización más compleja.

### 3.2. Diseño optimizado de un PSS clásico

Para hacer una comparación justa con un sistema cuya acción de control se logra como una solución de un problema de optimización, como MPC, se determinaron los parámetros óptimos para el CPSS, esto es  $K_s$ ,  $T_1$  y  $T_2$ , para diferentes potencias activas  $P$  analizadas. Para obtener los parámetros del CPSS se utilizó el algoritmo de optimización PSO, con la función objetivo (6). Esta función penaliza el estado del sistema en el tiempo de simulación  $T_f$  para que el estado converja al origen en tiempo mínimo, además de exigir que el esfuerzo de control sea mínimo (Abido, 2002)

$$\min_{\{K_s, T_1, T_2\}} J(P) = \sum_{j=1}^{T_f} x(k+j)^T R x(k+j) + \lambda \Delta V_s(k+j-1)^2 \quad (6)$$

En (Milla, Duarte-Mermoud, 2016) se presenta una mejora a este método.

## 4. Aplicación Simulada

En esta sección se presentan los resultados de los diseños del MPPSS y del CPSS, ambos optimizados usando PSO, los cuales se emplean para amortiguar los modos de oscilación en el sistema SMIB mostrado en la Figura 1. El estudio se realiza cuando se aplican simultáneamente perturbaciones sobre las variables de estado  $\Delta\omega_r$ ,  $\Delta\delta$ ,  $\Delta\psi_{fd}$  y  $\Delta V_1$ , considerando diferentes niveles de potencia activa, manteniendo fija la potencia reactiva, tanto para condiciones normales (doble circuito en funcionamiento) como en condiciones de falla de uno de los circuitos de la línea de transmisión. Algunos de los resultados que se presentan en esta sección ya han sido publicados en (Duarte-Mermoud and Milla, 2016) y se incluyen aquí por completitud del estudio. Otros resultados adicionales se muestran en la Sección 5 y corresponden a otro estudio de caso en el que se consideran perturbaciones por separado de diferentes magnitudes sobre las variables  $\Delta\delta$ ,  $\Delta\psi_{fd}$  y  $\Delta V_1$ , de modo de estudiar su efecto sobre las otras variables del sistema SMIB.

Los parámetros resultantes optimizados con PSO para el MPPSS se presentan a continuación en la ecuación (7).

$$R = \begin{bmatrix} 3.1 \times 10^{13} & 0 & 0 & 0 \\ 0 & 5.2 \times 10^{15} & 0 & 0 \\ 0 & 0 & 7.2 \times 10^1 & 0 \\ 0 & 0 & 0 & 9 \times 10^3 \end{bmatrix}, \quad \lambda = 2.1 \times 10^5 \quad (7)$$

Notar que en  $R$  el parámetro resultante más grande es el que penaliza el cambio en el ángulo  $\Delta\delta$ , justamente la variable de mayor importancia para el sistema SMIB.

Las condiciones iniciales escogidas para el vector de estado fueron  $x(0) = [0.001 \quad 0.01 \quad 0.001 \quad 0.001]^T \in \mathcal{R}^4$ . El intervalo de control es 0,1 [s] y el horizonte de predicción utilizado fue de 10 (1 [s]).

Los parámetros resultantes del CPSS, también optimizados

con PSO, se encuentran resumidos en la Tabla 1, para diferentes niveles de operación definidos por la potencia activa transmitida.

El estudio del CPSS se realiza con fines de comparar la estrategia avanzada MPPSS, con respecto a un estabilizador clásico como es el CPSS.

Tabla 1: Parámetros óptimos para el CPSS

P [p.u.]	$K_s$	$T_1$	$T_2$
0,5	10,20	0,174	0,0550
0,6	10,01	0,184	0,0450
0,7	9,96	0,177	0,0421
0,8	9,78	0,199	0,0398
0,9	9,46	0,156	0,0342
1,0	9,77	0,166	0,0330

A continuación en la Tabla 2, tomada de (Duarte-Mermoud and Milla, 2016), se presentan los resultados de aplicar al SMIB ambos controladores diseñados, para diferentes niveles de potencia activa  $P$  entre 0,5 y 1,0[p.u.], fijando  $Q$  en 0,3[p.u.],  $|E_r|=1$ [p.u.] y  $E_b=1$  [p.u.]. Se muestran los resultados para una operación normal del SMIB, es decir cuando los 2 circuitos de transmisión de la conexión están presentes, representando una impedancia equivalente  $X_e=0,4752$  [p.u.] y la tensión de transmisión del sistema SMIB es  $E_r=1$  [p.u.]. Se incluye el valor de la función objetivo  $J$  ( $FO_j$ ) mostrada en (5) tanto para el CPSS y como para el MPPSS, calculadas sobre un intervalo de 20[s].

Adicionalmente se muestra el tiempo de establecimiento  $T_{s\Delta\delta}$  de la variable  $\Delta\delta$  obtenido para cada esquema de control. Cabe hacer notar que en la Tabla 2 (así como también en las Tablas 3 a 6), el tiempo de estabilización que se calcula es el tiempo transcurrido para llegar y permanecer dentro de la banda de error del  $\pm 2\%$  del valor final. En la parte inferior de dicha la Tabla 2 se muestran los porcentajes de mejora de la  $FO_j$  y el  $T_{s\Delta\delta}$  al usar ambos esquemas, calculados mediante las ecuaciones (8) y (9), respectivamente.

$$\text{Mejora}_{FO} = \frac{(FO_{j\_CPSS} - FO_{j\_MPPS}) \times 100}{FO_{j\_CPSS}} \quad (8)$$

$$\text{Mejora}_{T_{s\Delta\delta}} = \frac{(T_{s\Delta\delta\_CPSS} - T_{s\Delta\delta\_MPPS}) \times 100}{T_{s\Delta\delta\_CPSS}} \quad (9)$$

De la Tabla 2 se observa una mejora promedio de 32,16% en la  $FO_j$  del MPPSS, en comparación con el CPSS. Del mismo modo, hay una mejoría promedio del 69,70% en el tiempo de asentamiento de  $T_{s\Delta\delta}$  al usar MPPSS, en comparación con el CPSS. Para obtener los resultados de la Tabla 2 se utilizó una perturbación inicial consistente en una variación simultánea de 0,1% en  $\Delta\omega_r$ , 1% en  $\Delta\delta$ , 0,1 % en  $\Delta\psi_{fd}$  y 0,1% en  $\Delta V_1$ . Señalar que la convergencia de  $\Delta\delta$  a cero representa el amortiguamiento de la oscilación de potencia, principal objetivo del CPSS y MPPSS.

La Figura 5, tomada de (Duarte-Mermoud and Milla, 2016) muestra la evolución de las principales variables del sistema, para los niveles  $P=0,5$ [p.u.] y  $Q=0,3$ [p.u.], con los dos circuitos de la línea de transmisión conectados en el sistema SMIB (ver Figura 2) con una impedancia equivalente de  $X_e = 0,4752$  [p.u.], que incluye en este caso la impedancia de los dos circuitos de la línea de transmisión y la impedancia del transformador. En este caso se realizaron las mismas perturbaciones iniciales de 0,1% en  $\Delta\omega_r$ , 1% en  $\Delta\delta$ , 0,1 % en  $\Delta\psi_{fd}$  y 0,1% en  $\Delta V_1$ , las mismas usadas para calcular los índices mostrados en la Tabla 2.

Tabla 2: Simulaciones para variaciones de potencia activa P, y los dos circuitos conectados (Q=0,3[p.u.], |E<sub>t</sub>|=1[p.u.], E<sub>b</sub>=1 [p.u.], X<sub>e</sub>=0,4752 [p.u.]

P [p.u.]	$\angle E_t^\circ$ [p.u.]	FO <sub>J</sub> CPSS x10 <sup>16</sup>	FO <sub>J</sub> MPPSS x10 <sup>15</sup>	Ts <sub>Δδ</sub> CPSS [s]	Ts <sub>Δδ</sub> MPPSS [s]
0,5	13,8	1,35	9,54	5,90	2,00
0,6	16,6	1,20	8,06	5,90	1,90
0,7	19,5	1,09	7,11	6,00	1,80
0,8	22,5	1,01	6,43	6,10	1,80
0,9	25,5	0,94	6,33	6,10	1,70
1,0	28,5	0,88	6,45	6,00	1,70
		media	6,00	6,00	1,82

P [p.u.]	$\angle E_t^\circ$ [p.u.]	Mejora FO %	Mejora Ts <sub>Δδ</sub> %
0,5	13,8	29,60	66,10
0,6	16,6	32,21	67,79
0,7	19,5	35,16	70,00
0,8	22,5	36,26	70,49
0,9	25,5	32,63	72,13
1,0	28,5	27,11	71,66
	media	32,16	69,70

En la Figura 5 se muestra la evolución temporal de la variable de estado x del sistema SMIB (compuesta por Δω<sub>r</sub>, Δδ, Δψ<sub>fd</sub> y ΔV<sub>1</sub>). Además, por su importancia, se muestran en figuras separadas el comportamiento comparativo de Δδ y Δω<sub>r</sub>, para el CPSS y el MPPSS (ver Figura 5). También se incluyen gráficas separadas con la evolución de la acción de control ΔV<sub>s</sub>, para el CPSS y el MPPSS (ver Figura 5). Se comparan en detalle las variaciones del ángulo Δδ para los dos controladores, cuya convergencia es el indicador más importante. Finalmente, y para mayor información, se detallan también las variaciones de frecuencia Δω<sub>r</sub> y sus respectivas acciones de control ΔV<sub>s</sub>.

Para verificar el comportamiento de ambos controladores bajo distintas condiciones de operación del sistema SMIB (por ejemplo con niveles P=0,9[p.u.] y Q=0,3[p.u.], con los dos circuitos de la línea de transmisión conectados i.e. X<sub>e</sub> = 0,4752 [p.u.]), el lector puede consultar (Duarte-Mermoud and Milla, 2016).

### 5. Resultados Simulados Complementarios

Para complementar el trabajo realizado en (Duarte-Mermoud and Milla, 2016), se realizó una serie relevante de nuevos estudios del MPPSS diseñado, los cuales se presentan a continuación.

En la Tabla 3 se presenta un resumen de simulaciones, variando solo la perturbación de ángulo Δδ desde 1% a 16%. Se presentan los tiempos de establecimiento Ts<sub>Δδ</sub> para esta señal, tanto al usar el control CPSS como el MPPSS.

Además, en la Tabla 3 se muestra el porcentaje de mejora en el tiempo de establecimiento Ts<sub>Δδ</sub>, (calculado de acuerdo a (9)) para el sistema con dos circuitos conectados, con potencias P=0.5 [p.u.] y Q=0.3 [p.u.], y una perturbación inicial para las restantes variables de 0,1% en Δω<sub>r</sub>, 0,1% en Δψ<sub>fd</sub> y 0,1% en ΔV<sub>1</sub>.




Figura 5: Simulación con los dos circuitos conectados y niveles de potencia P=0,5[p.u.] y Q=0,3[p.u.]. Perturbaciones iniciales de 0,1% en Δω<sub>r</sub>, 1% en Δδ, 0,1 % en Δψ<sub>fd</sub> y 0,1% en ΔV<sub>1</sub>.

Tabla 3: Resumen de rendimiento del control CPSS y MPSS versus tamaño de la perturbación sobre Δδ. Caso de dos circuitos conectados. (P=0,5 [p.u.], Q=0,3 [p.u.], X<sub>e</sub>=0,4752 [p.u.]

Perturbación Δδ %	Ts <sub>Δδ</sub> CPSS [s]	Ts <sub>Δδ</sub> MPPSS [s]	% Mejora Ts <sub>Δδ</sub>
1	6,3	2,2	65,07
2	5,2	2,1	59,61
3	5,0	2,0	60,00
4	4,0	2,1	47,50
5	4,0	2,1	47,50
6	3,9	2,1	46,15
7	3,8	2,1	44,73
8	3,8	2,2	42,10
9	3,8	2,2	42,10
10	3,7	2,3	37,83
11	3,7	2,3	37,83
12	3,7	2,3	37,83
13	3,6	2,3	36,11
14	3,6	3,1	13,88
15	3,6	3,1	13,88
16	2,7	3,2	0

En la Figura 6 se grafican los resultados de la Tabla 3, donde se aprecia como el efecto de la modelación en pequeña señal afecta negativamente el rendimiento del control predictivo, esto es debido a que un modelo de pequeña señal es válido solo en un intervalo pequeño en torno al punto de operación analizado (Kundur, 1994).

Se sabe que el control MPC basa su buen comportamiento en lo representativo que sea el modelo utilizado para el proceso (Camacho and Bordons, 2007) y en nuestro caso la representatividad del modelo se va perdiendo a medida que forzamos mayores variaciones de sus variables de entrada. Luego, como se muestra en la Figura 6, se puede garantizar un buen comportamiento (mejorías de  $T_{s\Delta\delta}$  superiores al 10%), para perturbaciones sobre  $\Delta\delta$  menores al 15%.




Figura. 6. Rendimiento del control MPC versus tamaño de perturbaciones en  $\Delta\delta$  para  $P=0,5$ [p.u.],  $Q=0,3$ [p.u.] y con el doble circuito conectado.

En la Tabla 4 se presenta un resumen de simulaciones, variando solo la perturbación de ángulo  $\Delta\delta$  desde 1% al 10%, para el caso en que un circuito se encuentra fuera de servicio. Se muestran los tiempos de establecimiento  $T_{s\Delta\delta}$  para la señal  $\Delta\delta$  al usar el esquema de control CPSS y el MPPSS, así como también el porcentaje de mejora en el tiempo de establecimiento  $T_{s\Delta\delta}$ , calculado usando la ecuación (9). Esta prueba se realiza para el sistema con solo un circuito conectado ( $X_e=0,6500$  [p.u.]), con niveles de potencia  $P=0,9$  [p.u.] y  $Q=0,3$  [p.u.], y una perturbación inicial para las restantes variables de  $0,1\%$  en  $\Delta\omega_r$ ,  $0,1\%$  en  $\Delta\psi_{fd}$  y  $0,1\%$  en  $\Delta V_1$ .

Tabla 4: Resumen del rendimiento del control MPC versus tamaño de la perturbaciones en  $\Delta\delta$ . Caso de un circuito conectado. ( $P=0,5$  [p.u.],  $Q=0,3$  [p.u.],  $X_e=0,6500$  [p.u.]

% Perturbación $\Delta\delta$	$T_{s\Delta\delta}$ CPSS [s]	$T_{s\Delta\delta}$ MPPSS [s]	% Mejora $T_{s\Delta\delta}$
1	6,3	1,9	69,84
2	5,3	1,8	66,03
3	4,7	1,8	61,70
4	4,3	1,8	58,13
5	4,1	1,9	53,65
6	3,5	1,9	45,71
7	3,4	2,0	41,17
8	3,3	2,7	18,18
9	3,2	2,8	12,50
10	3,2	3,2	0

En la Figura 7 se grafican los resultados de la Tabla 4. En ella se aprecia como efecto del modelación en pequeña señal afecta el rendimiento del MPC. Solo se puede garantizar un buen comportamiento (mejorías de  $T_{s\Delta\delta}$  superiores al 10%), para perturbaciones sobre  $\Delta\delta$  menores del 9%, lo cual es un tamaño razonable para que sea válido el modelo de pequeña señal del sistema SMIB utilizado.

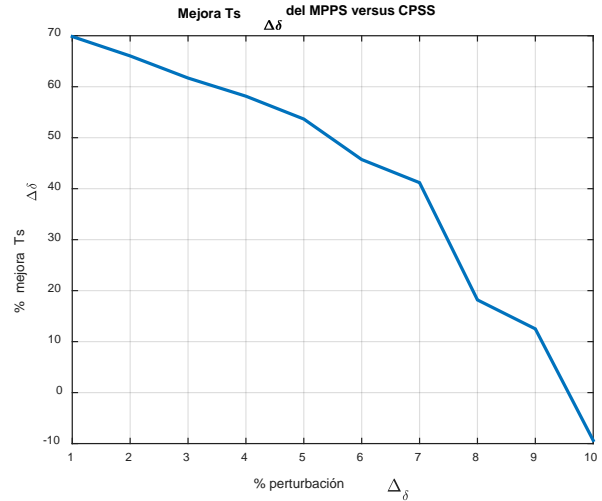


Figura. 7. Rendimiento del control MPC versus tamaño de perturbaciones sobre  $\Delta\delta$ , para  $P=0,9$ [p.u.]  $Q=0,3$ [p.u.] y un circuitos conectado.

En la Tabla 5 se presenta un resumen de simulaciones, variando solo la perturbación de ángulo  $\Delta\psi_{fd}$  desde 1% a 16%. Se presentan los tiempos de establecimiento  $T_{s\Delta\psi_{fd}}$  para esta señal  $\Delta\psi_{fd}$ , correspondientes al control CPSS y al MPPSS. También se muestra el porcentaje de mejora en el tiempo de establecimiento  $T_{s\Delta\psi_{fd}}$ , calculado usando la ecuación (9) pero para la variable  $\Delta\psi_{fd}$ , para el sistema SMIB con dos circuitos conectados y niveles de potencia  $P=0,9$  [p.u.] y  $Q=0,3$  [p.u.], con perturbaciones iniciales de las restantes variables de  $0,1\%$  en  $\Delta\omega_r$ ,  $0,1\%$  en  $\Delta\delta$  y  $0,1\%$  en  $\Delta V_1$ .

Tabla 5: Rendimiento del MPC v/s tamaño de las perturbaciones en  $\Delta\psi_{fd}$ . Caso de dos circuitos conectados. ( $P=0,5$  [p.u.],  $Q=0,3$ [p.u.],  $X_e=0,4752$ )

% Perturbación $\Delta\psi_{fd}$	$T_{s\Delta\psi_{fd}}$ CPSS [s]	$T_{s\Delta\psi_{fd}}$ MPPSS [s]	% Mejora $T_{s\Delta\psi_{fd}}$
1	9,5	2,1	77,65
2	9,4	2,0	78,72
3	9,4	1,8	80,85
4	9,4	1,8	80,85
5	9,4	1,7	81,91
6	9,4	1,7	81,91
7	9,3	1,6	82,97
8	9,4	1,6	82,97
9	9,4	1,6	82,97
10	9,4	1,6	82,97
11	9,4	1,6	82,97
12	9,4	1,8	80,85
13	9,4	2,2	76,59
14	9,3	2,3	75,53
15	9,3	2,5	73,40
16	9,3	2,6	72,34



En la Figura 8 se grafican estos resultados de la Tabla 5, donde se aprecia como el control MPC puede garantizar un buen comportamiento (mejorías de  $T_{s_{\Delta\psi_{fd}}}$ , superiores al 60%), para perturbaciones incluso del 20% sobre  $\Delta\psi_{fd}$ .

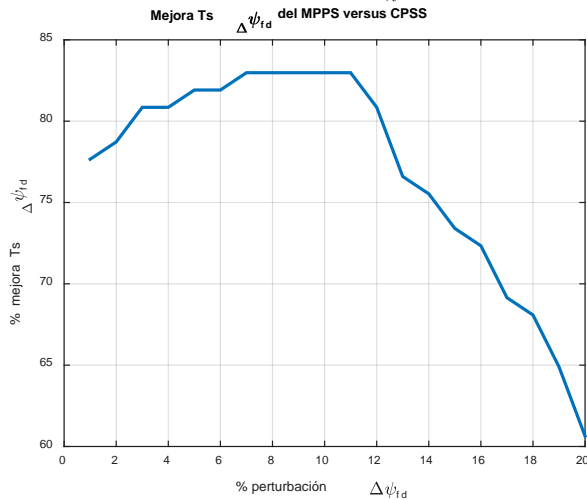


Figura 8. Rendimiento del control MPC versus tamaño de perturbaciones sobre  $\Delta\psi_{fd}$ , para  $P=0,9$ [p.u.]  $Q=0,3$ [p.u.] y los dos circuitos conectados.

En la Figura 9 se presentan los efectos de aplicar una perturbación del 10% en la señal de flujo de campo  $\Delta\psi_{fd}$  (además de la señal de perturbación de oscilación de potencia  $\Delta\delta=1\%$ ).

Notar de la Figura 9 como el controlador predictivo MPPSS logra controlar el sistema en menor tiempo que el control CPSS logrando una mejora de sobre el 70%.

En la Tabla 6 se muestra un resumen de simulaciones, variando la perturbación de ángulo  $\Delta V_1$  desde 1% al 16%. Se presentan los tiempos de establecimiento para esta señal correspondientes al control CPSS y al MPPSS. También se presenta el porcentaje de mejora en el tiempo de establecimiento  $T_{s_{\Delta V_1}}$ , calculado usando la ecuación (9) pero para la variable  $\Delta V_1$ , para el sistema con dos circuitos conectados, niveles de potencia  $P=0,9$  [p.u.] y  $Q=0,3$  [p.u.], además de una perturbación en las restantes variables de 0,1% en  $\Delta\omega_r$ , 0,1% en  $\Delta\delta$  y 0,1% en  $\Delta\psi_{fd}$ .

Tabla 6: Resumen del rendimiento del control MPC versus tamaño de perturbaciones en  $\Delta V_1$ . Caso de dos circuitos conectados. ( $P=0,5$  [p.u.],  $Q=0,3$  [p.u.],  $X_e=0,4752$  [p.u.])

% Perturbación $\Delta V_1$	$T_{s_{\Delta V_1}}$ CPSS [s]	$T_{s_{\Delta V_1}}$ MPPSS [s]	% Mejora $T_{s_{\Delta V_1}}$
1	9,4	2,5	73,40
2	9,4	2,5	73,40
3	9,4	2,5	73,40
4	9,4	2,6	72,34
5	9,4	2,7	71,27
6	9,4	2,7	71,27
7	9,3	2,9	68,81
8	9,4	3,0	68,08
9	9,4	3,3	64,89
10	9,4	3,4	63,82
11	9,4	3,4	63,82
12	9,4	3,5	62,76
13	9,4	4,0	57,44
14	9,4	4,1	56,38
15	9,3	4,2	54,83
16	9,3	4,4	52,68




Figura 9. Simulación de dos circuitos conectados para  $P=0,9$ [p.u.] y  $Q=0,3$ [p.u.], y perturbaciones iniciales  $\Delta\psi_{fd}=10\%$  y  $\Delta\delta=1\%$ .

En la Figura 10 se grafican estos resultados, donde se aprecia como el control MPC puede garantizar un buen comportamiento (mejorías de  $T_{s_{\Delta V_1}}$  superiores al 40%), para perturbaciones incluso del 20% sobre  $\Delta V_1$ .

La Figura 11 muestra los resultados con los dos circuitos de la línea de transmisión en el sistema SMIB y se presentan los efectos de aplicar una perturbación del 5% en la señal de voltaje  $\Delta V_1$  (además de la señal de perturbación de oscilación de potencia  $\Delta\delta=1\%$ ). Notar como el controlador predictivo MPPSS logra controlar el sistema en menor tiempo que el control CPSS, logrando beneficios superiores al 70%.

Observar que no se muestran variaciones mayores al 0,1% en  $\Delta\omega_r$ , ya que se determinó que ante variaciones mayores los controles CPSS y MPPSS no logran controlar el sistema. Esto es debido a que el sistema de control primario de frecuencia no está incluido en el diagrama que se estudia.




Figura 10. Rendimiento del control MPC versus perturbaciones sobre  $\Delta V_1$  niveles de potencia  $P=0,9$ [p.u.],  $Q=0,3$ [p.u.] y  $X_e=0,4752$  [p.u.].

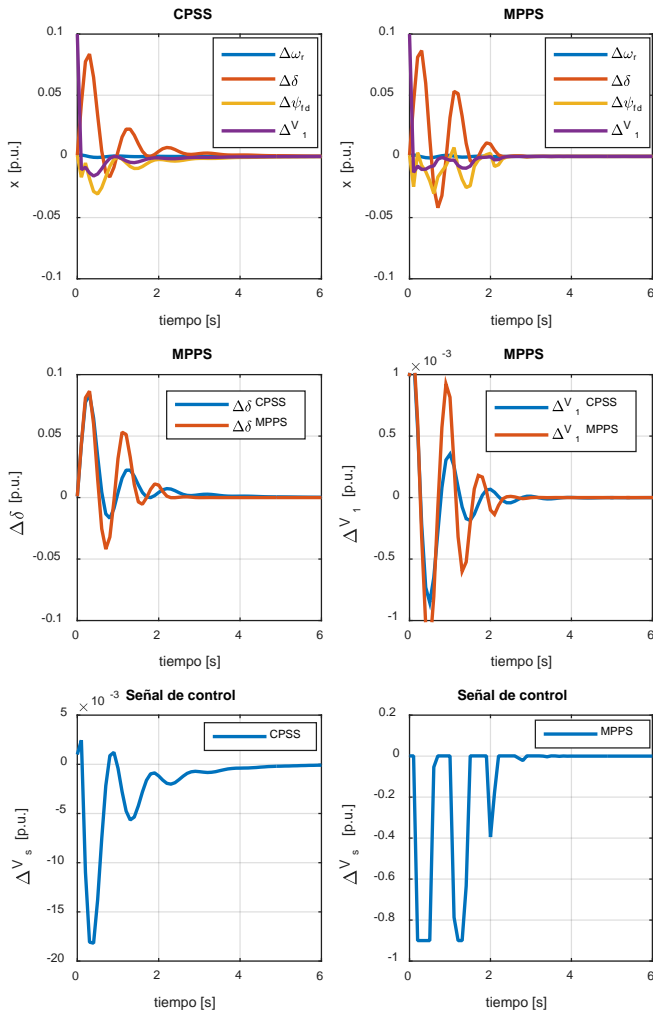


Figura 11. Simulación de dos circuitos conectados con  $P=0,9$  [p.u.] y  $Q=0,3$ [p.u.]. Perturbaciones iniciales  $\Delta V_1 =5\%$  y  $\Delta\delta=1\%$ .

**6. Conclusiones**

En este trabajo se diseñó un estabilizador predictivo de potencia (MPPSS) para mejorar las oscilaciones frente a perturbaciones en un sistema de alimentación compuesto por

una sola máquina y una barra infinita (SMIB).

El MPPSS propuesto proporciona las entradas de control óptimas y los parámetros de diseño se optimizaron utilizando la técnica de PSO. Para la comparación se utilizó un estabilizador convencional del sistema de potencia (CPSS), con parámetros también optimizados con PSO. Los estudios por simulación en el sistema de potencia SMIB muestran que el enfoque MPPSS propuesto tiene un mejor rendimiento que el PSS clásico para operación en todos los niveles de potencia y cambios (perturbaciones) en los parámetros del sistema considerados. En particular, se puede garantizar un buen comportamiento del controlador predictivo en la medida que no se supere una perturbación del 9% en la señal del ángulo  $\Delta\delta$ , lo cual es razonable ya que se está trabajando con un modelo aproximado del sistema SMIB de pequeña señal.

Los efectos de aplicar una perturbación del 10% en la señal de flujo de campo  $\Delta\psi_{fd}$  con el controlador predictivo MPPSS logra controlar el sistema en menor tiempo que el control CPSS, logrando un beneficio de sobre el 70%. Resultados semejantes se logran al aplicar una variación del 10% en el voltaje de salida  $\Delta V_1$ . Estos resultados confieren un grado de robustez al controlador diseñado.

Como trabajo futuro, se propone analizar otras estructuras clásicas de PSS, conectadas a sus correspondientes circuitos de excitación para los cuales fueron diseñados y analizar su comportamiento frente al comportamiento del control predictivo presentado en este trabajo. Además, se proyecta incluir pruebas de estabilidad del controlador con el cálculo de la región terminal  $\Omega$  y una función de Lyapunov  $V(x)$  asociada. Por último, en un futuro trabajo se confeccionará una curva Pareto óptima entre los parámetros  $R$  y  $\lambda$  (Sección 3.1) y se analizarán otros puntos factibles de solución de nuestro problema de optimización del control MPC.

**Agradecimientos**

Este trabajo ha contado con el apoyo de CONICYT-Chile, a través del proyecto FB0809 “Centro Avanzado de Tecnología para la Minería” (AMTC)”. El segundo autor agradece el apoyo de CONICYT / FONDECYT / (N ° 3140604).

**Referencias**

Abido. M.A., 2002. Optimal design of power-system stabilizers using particle swarm optimization, IEEE Transactions on Energy Conversion, vol. 17 (3), pp. 406 – 413.  
 Bratton, D., Kennedy, J., 2007. Defining a standard for particle swarm optimization, Proceedings of the IEEE Swarm Intelligence Symposium, Honolulu, USA, pp. 120–127.  
 Camacho, E.F., Bordons, C., 2007. Model Predictive Control. Springer-Verlag, 2 Ed.  
 Carlisle, A., Dozier, G., 2001. An off-the-shelf PSO. In Proceedings of the Particle Swarm Optimization Workshop, Seoul, Korea, pp. 1– 6.  
 Cazzaniga, P., Nobile, M.S., Besozzi, D., 2015. The impact of particles initialization in PSO: parameter estimation as a case in point. Proceedings of IEEE Conference on Computational Intelligence in Bioinformatics and Computational Biology, Niagara Falls, Canada, pp. 1-8.  
 Chatterjee, A., Ghoshal, S.P., Mukherjee, V., 2011. Chaotic ant swarm optimization for fuzzy-based tuning of power system stabilizer. Electrical Power and Energy Systems, vol. 33 pp. 657–672.  
 Clerc, M., The swarm and the queen: Towards a deterministic and adaptive particle swarm optimization, in Proc. 1999 ICEC, Washington, DC, pp. 1951-1957.  
 Clerc, M., Kennedy, J., 2002. The particle swarm – Explosion, stability, and convergence in a multidimensional complex space”, IEEE Transactions on Evolutionary Computation, Vol. 6, No. 1, pp. 58-73.

- Del Re, L., Allgöwer, F., Glielmo, L., Guardiola, C., Kolmanovsky, I. (Eds.), 2010. *Automotive Model Predictive Control: Models, Methods and Applications*. Springer-Verlag.
- Duarte-Mermoud, M.A., Milla, F., 2016. Model Predictive Power Stabilizer Optimized by PSO. *Proceedings of IEEE ICA Conference & XXII Congress of ACCA*, 19-21 October, 2016, Curicó, Chile. Vol. 1, pp. 673-679.
- Eberhart, R., Kennedy, J., 1995a. A new optimiser using particle swarm theory. In: *Proceedings of the Sixth International Symposium on Micromachine and Human Science (MHS)*. Nagoya, Japan, pp. 39 – 43.
- Eberhart, R., Kennedy, J., 1995b. Particle swarm optimization. In *Proceedings of IEEE International Conference on Neural Networks (ICNN)*. Vol. 4. Piscataway, NJ, pp. 1942 – 1948.
- Eberhart, R.C., Shi, Y. 2000. Comparing Inertia Weights and Constriction Factors in Particle Swarm Optimization, In *Proceedings of the 2000 Congress on Evolutionary Computing*, Vol. 1, pp. 84-88, 2000.
- Ford, J.J., Ledwich, G., Dong, Z.Y., 2008. Efficient and robust model predictive control for first swing transient stability of power systems using flexible AC transmission systems devices, *Generation, Transmission & Distribution, IET*, vol. 2 (5), pp.731-742.
- IEEE, 2005. IEEE 421.5. “IEEE Recommended Practice for Excitation System Models for Power System Stability Studies”. IEEE-SA Standards. USA.
- Kahl, M., Leibfried T., 2013. Decentralized Model Predictive Control of Electrical Power Systems. In *Conference on Power Systems Transients (IPST2013)* in Vancouver, Canada, Available: [http://ipstconf.org/papers/Proc\\_IPST2013/13IPST043.pdf](http://ipstconf.org/papers/Proc_IPST2013/13IPST043.pdf)
- Karnik, S.R., Raju, A.B., Raviprakash, M.S., 2009. Robust Design of Power System Stabilizer using Taguchi Technique and Particle Swarm Optimization, in *Second International Conference on Emerging Trends in Engineering and Technology*, Nagpur, India, vol. 1, No. 1, pp. 19-25.
- Kennedy J., and Eberhart. R.C., 2001. *Swarm Intelligence*. Morgan Kaufmann.
- Kundur P., 1994. *Power system stability and control*. New York: McGraw-Hill.
- Mayne, D.Q., Rawlings, J.B., Rao, C.V., Scokaert. P.O.M., 2000. Constrained model predictive control: stability and optimality. In *Automatica*, vol.36, pp.789–814.
- Milla, F., Duarte-Mermoud, M.A., 2016. Predictive Optimized Adaptive PSS in a Single Machine Infinite Bus. *ISA Transactions*. vol. 63, pp. 315 – 327.
- Ocampo-Martínez C., 2010. *Model Predictive Control of Wastewater Systems*. Springer-Verlag.
- Phulpin, Y., Hazra, J., Ernst, D., 2011. Model predictive control of HVDC power flow to improve transient stability in power systems. In *IEEE International Conference on Smart Grid Communications (SmartGridComm)*, Brussels, pp. 593 – 598.
- Rajkumar, V., Mohler, R.R., 1994. Nonlinear predictive control for the damping of multimachine power system transients using FACTS devices, In *Proceedings of the 33rd Conference on Decision and Control*, Lake Buena Vista, Florida, USA, vol. 4, pp. 4074 – 4079.
- Sebaa, K., Moulahoum, S., Houassine H., and Kabache., N. 2012. Model Predictive Control to improve the power system stability. In *13th International Conference on Optimization of Electrical and Electronic Equipment (OPTIM)*, Brasov, Rumania, pp. 208 – 212.
- Shahriar, M.S., Ahmed, M.A., Ullah, M.S., 2012. Design and Analysis of a Model Predictive Unified Power Flow Controller (MPUPFC) for Power System Stability Assessment. *International Journal of Electrical & Computer Sciences IJECS-IJENS* vol: 12 No: 04
- Shi, Y., Eberhart R.C., 1998. A modified particle swarm optimizer, in *Proc. of the IEEE International Conference on Evolutionary Computation, IEEE World Congress on Computational Intelligence*, Anchorage, USA: pp. 69-73, May 1998
- Wang, L., Cheung, H., Hamlyn, A., Cheung. R., 2009. Model prediction adaptive control of inter-area oscillations in multi-generators power systems. In *Power & Energy Society General Meeting*, Toronto, Canada. pp. 1 – 7.
- Zambrano-Bigiarini, M., Clerc, M., Rojas. R., 2013. Standard Particle Swarm Optimization 2011 at CEC-2013: A baseline for future PSO improvements. In *Evolutionary Computation (CEC), IEEE Congress*, New York, USA, pp. 2337-2344.
- Zheng, T. Ed., 2011. *Advanced Model Predictive Control*. InTech.

