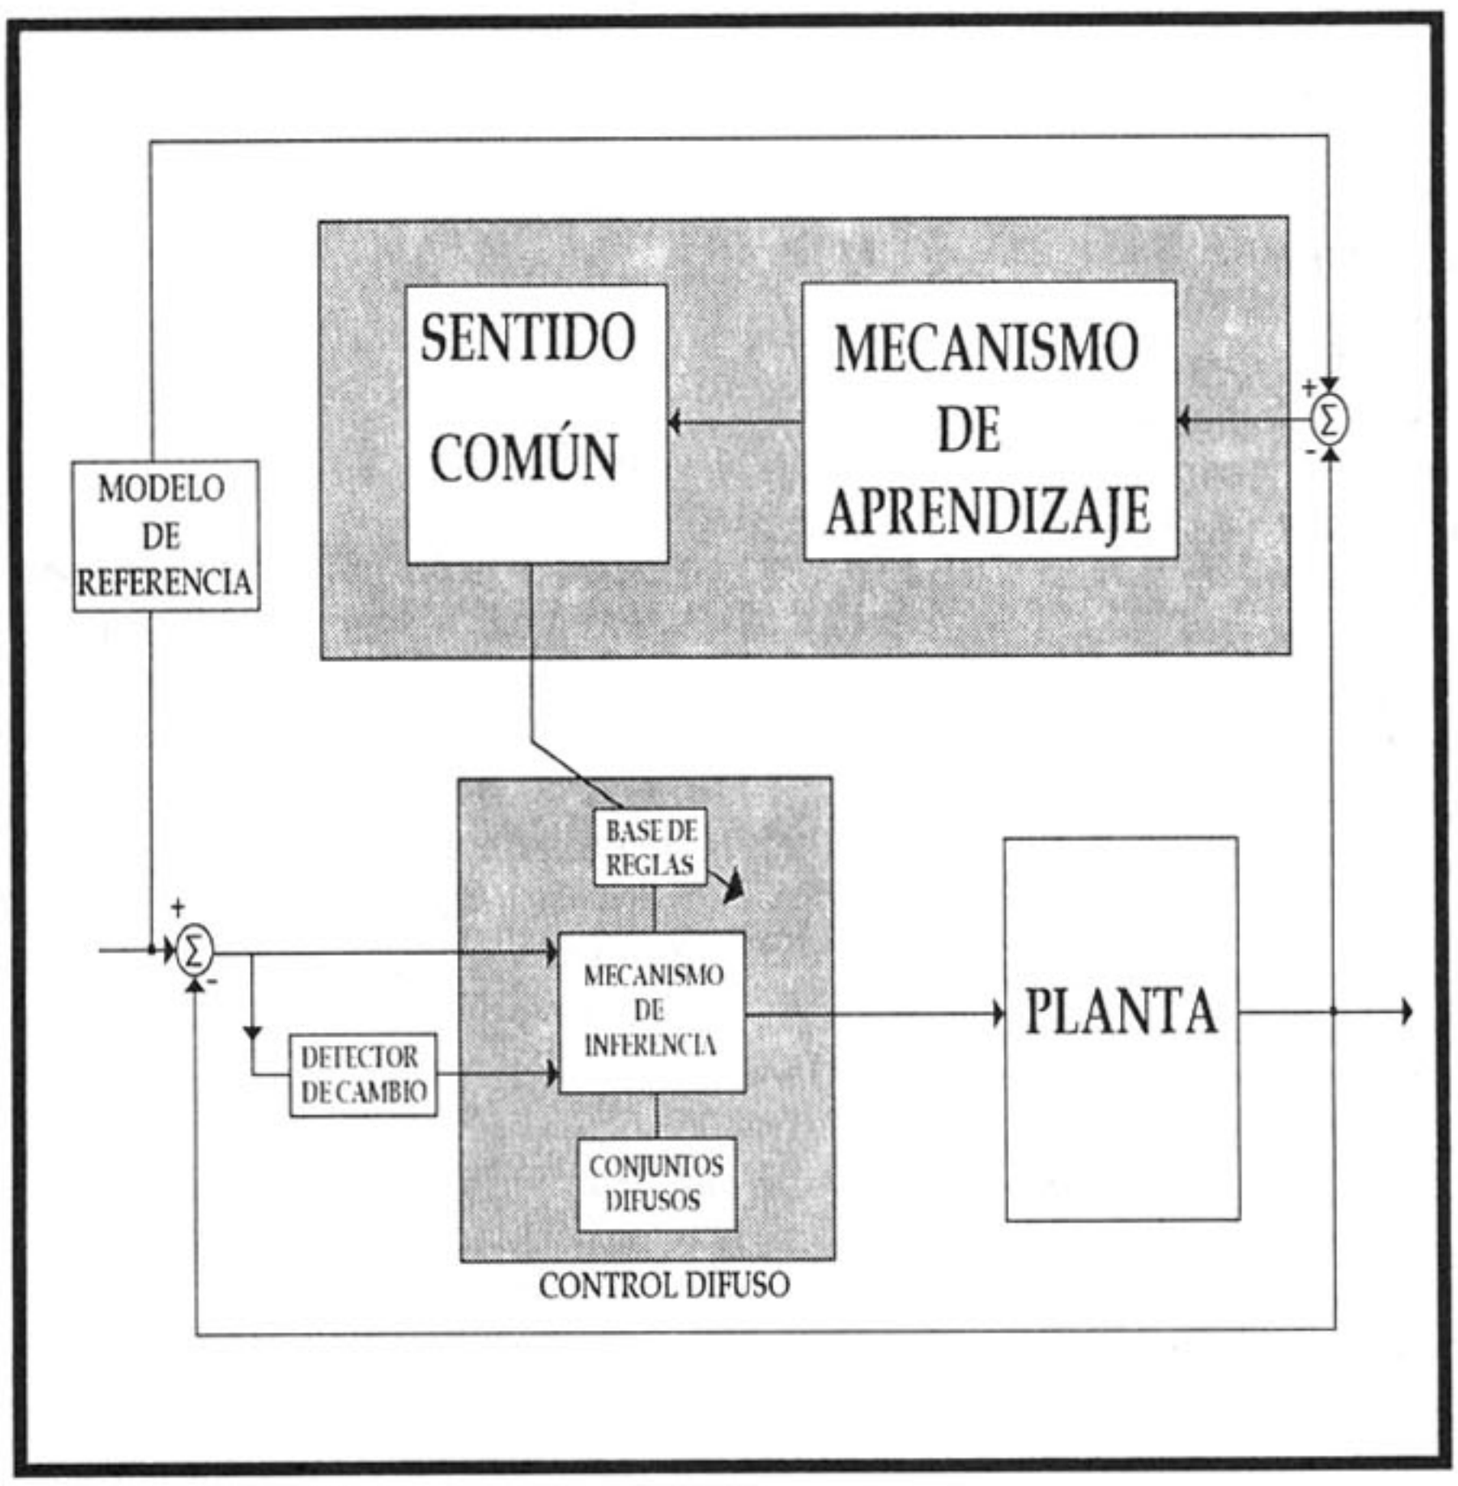
Sentido común para controladores difusos extrapolando FMRLC*



❒ **Manuel Betancur Betancur,**
Profesor Asociado,
Universidad Pontificia Bolivariana

❒ **Diego Ignacio Marín Arango,**
Ingeniero Electrónico
Celsa S.A.

❒ **Marta Elena Pedraza Díaz,**
Ingeniera Electrónica
Universidad Pontificia Bolivariana

GRIAL - Grupo de Investigación en Automática UPB
Universidad Pontificia Bolivariana
Circular 1 #70-01, Blq. 11 - Of. 259
Medellín, Colombia, S.A.
GRIAL@UPB.EDU.CO

RESUMEN

Se implementa una mejora al método FMRLC* fundamentada en la emulación burda del sentido común humano, la cual permite acelerar el proceso de aprendizaje para ciertas situaciones difíciles. Para lograrla se propone un nuevo algoritmo "extrapolador del aprendizaje". Se prueba en el laboratorio, se analizan sus resultados, y se proponen más alternativas.

PALABRAS CLAVE

Control difuso y sentido común.

ABSTRACT

A method for upgrading the FMRLC is proposed, based on a primitive rough emulation of human common sense which allows to accelerate the learning curve in difficult situations.*
A "learning extrapolation" idea is explored and tested in laboratory. Results are presented, as well as plausible alternatives for further improvement

KEYWORDS

Fuzzy control, common-sense

* **F**uzzy **M**odel **R**eference **L**earning **C**ontrol (Controlador Difuso con Aprendizaje por Referencia a Modelo)

* La Revista recibió este artículo en Mayo de 2.001

1. INTRODUCCIÓN

Este trabajo puede catalogarse en la temática de los sistemas bioinspirados. Busca emular en parte una faceta de la inteligencia natural conocida como "sentido común" para luego agregarla a un sistema de control difuso adaptativo y así mejorar su desempeño.

Como antecedente se tiene el trabajo preliminar que fue presentado en el XI-Congreso Latinoamericano de Control Automático [1]. En él se usó Matlab 5.3 para efectuar simulaciones con el algoritmo denominado Extrapolador del Aprendizaje. Se aplicó al caso de un controlador FMRLC para un buque tanque, planteado por Kevin Passino y Stephen Yurkovich en su texto *Fuzzy Control* [2].

En este artículo se reportará la culminación del proyecto con la presentación de un caso práctico experimental de aplicación.

Inicialmente se explicará conceptualmente el funcionamiento del algoritmo FMRLC, después se compararán cualitativamente los métodos de adaptación convencionales con aquellos que incluyen aprendizaje, tal como el FMRLC. Se hará énfasis en la desventaja de éstos para aprender por sí mismos en situaciones extremas y difíciles, justificando así la necesidad del nuevo algoritmo ExFMRLC (Extrapolador para el FMRLC). Finalmente se relacionará el aprendizaje con el sentido común humano, se explicará cómo implementar una aproximación del mismo en un controlador FMRLC y se analizarán los resultados experimentales.

2. FMRLC CONVENCIONAL

En el caso en consideración se usa una planta o proceso *SISO (Single input single output)*. Se definen dos variables para ejercer su control, el *error* ***e*** y el *cambio-en-error* ***de***, que se escogen como las entradas al controlador difuso. Para cada una de dichas variables se establece una clasificación dada por varias funciones de membresía, un total de ***n***=11 para la primera, y ***m***=11 para la segunda.

Las reglas del controlador difuso se representan por casillas en la matriz de reglas formadas al combinar las funciones de membresía de las dos variables de entrada, resultando así ***nxm*** reglas para el control de la planta. Ver figura 1.

Cada regla es responsable de las decisiones ***u*** que toma el controlador cuando la planta se encuentra en la zona de operación para la cual la regla fue definida y, dado que las zonas se traslapan, el proceso de concreción *(defuzzyfication)* se encarga de hacer una transferencia suave entre zonas; esto es, se combinan las decisiones tomadas por la regla de cada zona involucrada.

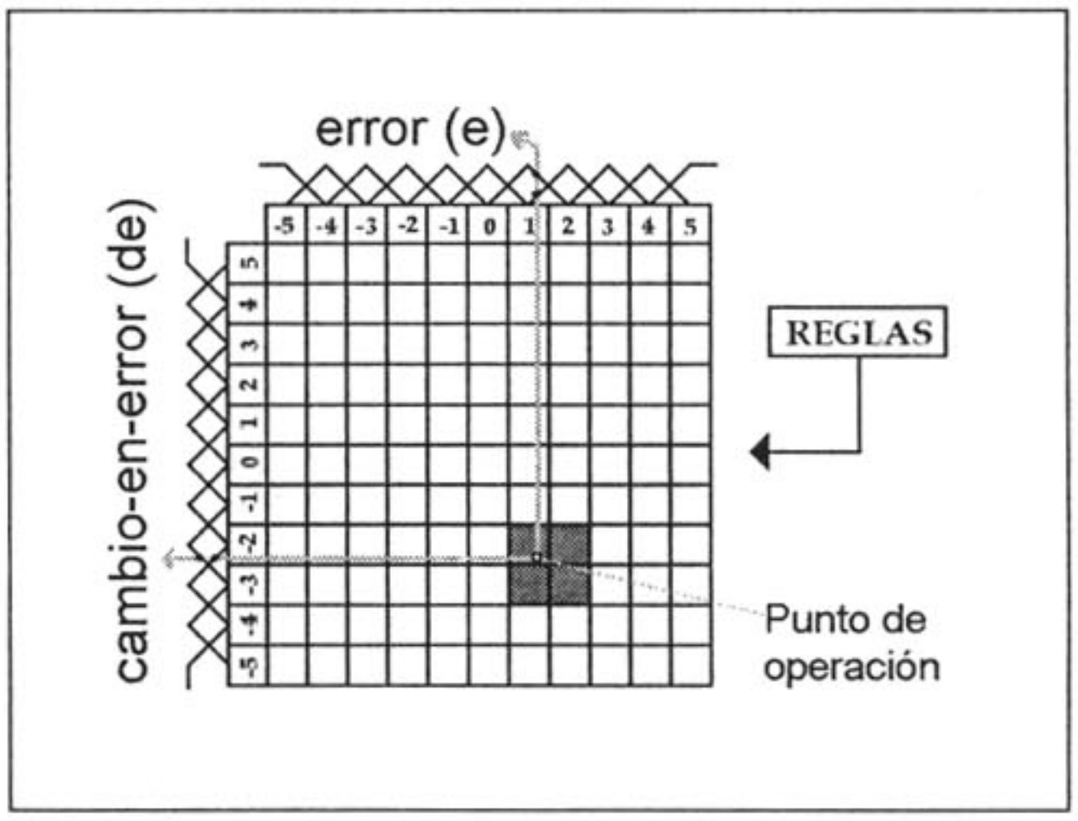


Figura 1. Representación de las reglas en un control difuso de dos entradas y una salida

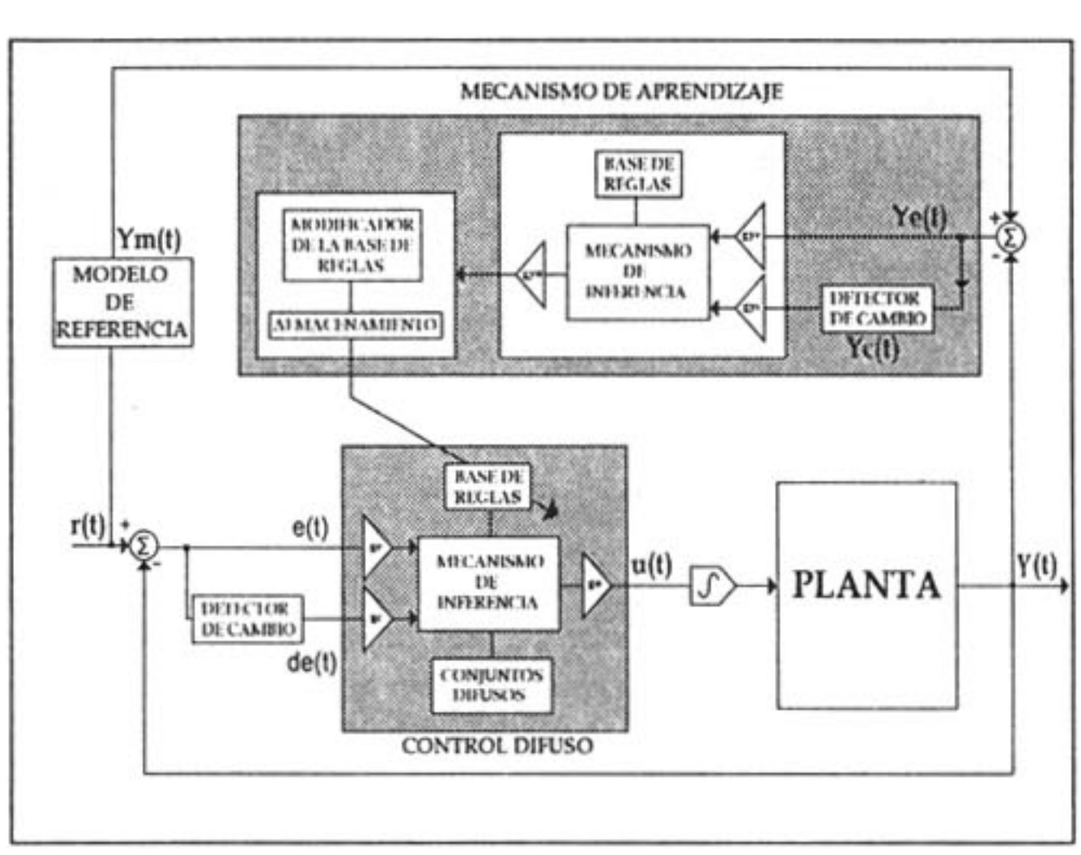


Figura 2. *Esquema del FMRLC convencional*

En la figura 2 se esquematiza el Mecanismo de Aprendizaje. Éste consiste en otro sistema difuso que tiene como entradas el error-de-referencia *Ye* y el cambio-en-error-de-referencia *Yc*, y como salida la magnitud del ajuste que debe realizarse a las reglas de las zonas en las cuales se está ejecutando la acción de control, es decir, la modificación necesaria a las reglas activas que en ese momento son responsables por los resultados del accionar del controlador.

Las reglas de dicho mecanismo de aprendizaje se fundamentan en el criterio de que si la salida de la planta se ajusta a lo previsto en el modelo de referencia, se deben dejar las reglas del controlador tal como

están, pero si nó, se deben modificar de tal manera que el accionar del controlador tienda a modificar la salida de la planta para que se parezca al modelo de referencia.

3. ADAPTACIÓN Y APRENDIZAJE

Los métodos adaptativos por modelo de referencia ajustan o sintonizan directamente los parámetros del controlador basándose en el desempeño relativo del sistema control-planta mientras trabaja en una determinada zona de operación. Las zonas se definen alrededor de un punto de operación y se pueden escoger arbitrariamente pequeñas siempre que los parámetros del controlador puedan permanecer constantes en cada zona y aún así obtener un desempeño adecuado.

Para el caso de los sistema de control adaptativo en que se definen los parámetros como globales, éstos pueden llegar a variar continuamente a lo largo de todo el rango de operación de la planta. Cuando los parámetros se sintonizan en una cierta zona se suponen como válidos aun en el evento de migrar a un zona vecina y sólo después de trabajar por un período de tiempo en la nueva zona de operación, se modificarán adecuadamente, "olvidando" por completo los ajustes anteriores de la zona inicial.

Si posteriormente el control regresa a la zona inicial, los parámetros actuales –en vez de los originales- serán considerados válidos y deberán ser ajustados otra vez con base en su nuevo desempeño. Es decir, que cada vez que retorna a una situación previamente experimentada debe "reaprender" la sintonización adecuada para los parámetros. ¡No tiene aprendizaje!

En cambio, los métodos de adaptación con aprendizaje, se caracterizan porque permiten recordar el ajuste adecuado de los parámetros para cada zona. Visto de otra manera, esto equivale a decir que en vez de unos pocos parámetros generales que deben ser ajustados en cada zona, se dispone de una gran cantidad de parámetros de alcance local, esto es, un juego de parámetros propios independientes para cada zona.

A esta última categoría pertenece el FMRLC, método en el cual los parámetros son las reglas difusas. Las diversas zonas de operación se definen con la combinación de las funciones de membresía de las entradas al controlador. Ver figura 1.

Una situación difícil o extrema se le presenta a un controlador cuando en determinado momento los parámetros que está usando difieren radicalmente de los que debería usar lo cual lo lleva a tomar decisiones erróneas afectando así el desempeño de la planta.

Esta situación se puede presentar por varias razones. Por ejemplo, en el momento del arranque inicial o también por el cambio súbito del modelo de la planta controlada.

Se estudiará aquí únicamente el primer caso dado que el segundo se puede resolver como una extensión a la solución del primero.

El interés se centrará en una situación en la cual el usuario ajusta los parámetros iniciales de la peor manera posible, quizás por error o quizás por desconocimiento del proceso o incluso por simple «sabotaje». Dicha situación se denotará en lo sucesivo como "*PeorSupuesto*" (*WorstGuess*)

¿Cómo se comporta un controlador ante una situación crítica como esa?

En el caso de un controlador adaptativo sin aprendizaje, iniciará el ajuste pero probablemente migrará a otra zona en virtud de sus decisiones equivocadas, a causa de los parámetros inadecuados. Sin embargo, aún si no logra readaptar sus parámetros adecuadamente en la zona inicial no tendrá el problema de pérdida de información al cambiar a otras zonas de operación pues el nuevo valor de los parámetros en cada zona se calcula a partir del anterior. En cierto modo, su incapacidad de recordar los valores adecuados para cada zona particular se convierte en una ventaja, dado que olvida también la «equivocación» inicial.

Por su parte el FMRLC, aunque exhibe comportamientos adecuados cuando sus parámetros se inicializan con una base de conocimiento vagamente aproximada a la ideal (*MejorSupuesto*), resulta ineficiente, saturante, e incluso inestable si la inicialización se hace con el *PeorSupuesto*. La razón radica en que aún si logra adaptar su conocimiento para la zona inicial, al migrar a una nueva zona vecina ésta contiene los parámetros originales brindados por el *PeorSupuesto*, los cuales están totalmente errados y por tanto tendrá que reiniciar el proceso de adaptación, creándose una cadena de eventos que se repite al cambiar nuevamente de zona.

Esta situación se agrava cuando debido a las malas decisiones tomadas a causa de los parámetros equivocados se abandona la zona de operación antes de lograr el ajuste de éstos, iniciando un ciclo vicioso así: Abandona la zona al tomar una decisión errónea por tener mal sintonizados los parámetros de control y no logra sintonizarlos para esa zona por haberla abandonado rápidamente.

Es dicha incapacidad del FMRLC para recuperarse eficientemente y sin saturaciones de un estado inicial *PeorSupuesto* la que se pretende eliminar, eso sí, sin alterar su desempeño en las condiciones normales de operación. Lo ideal sería propiciar la sinergia entre las bondades de la adaptación y las del aprendizaje.

4. SENTIDO COMÚN.

Por analogía con la inteligencia natural, el *PeorSupuesto* equivale a enseñar mentiras al controlador con aprendizaje, al programarle reglas falsas para cada caso o zona de operación posible.

A la luz de esa analogía se esperaría que un humano con una inteligencia promedio, actuando en lugar del controlador y al verse enfrentado a la misma situación *PeorSupuesto*, aplicase su sentido común y, después de darse cuenta de que algunas de las reglas que le fueron ofrecidas inicialmente –las que ha usado hasta el momento- no arrojan los resultados esperados, decidiese cambiarlas aplicando no sólo adaptación sino también reaprendizaje.

Estos cambios los haría siguiendo un patrón de "extrapolación" intuído de lo aprendido localmente en la zona de operación, alterando así tanto las reglas utilizadas hasta el momento como también todo el juego de reglas globales de las cuales es razonable sospechar que también estén equivocadas.

Por supuesto, este reaprendizaje por "extrapolación" no garantiza un adecuado ajuste global de los parámetros, pero sí los posicionará en un valor más cercano al ideal; de modo que cuando el proceso transite por nuevas zonas se puedan utilizar los parámetros "extrapolados" y hacerles los ajustes adecuados según su desempeño local.

Un ejemplo simple que muestra la peligrosidad del tipo de situaciones *PeorSupuesto* que se desean resolver con esta investigación puede elaborarse suponiendo que se establecen las reglas para controlar la ruta de un vehículo mediante un sistema difuso de dirección autónomo pero programándolo con reglas totalmente invertidas como las siguientes:

1ª Para virar a la **izquierda** un poco, accione el volante suavemente en sentido **horario**
2ª Para virar a la **derecha** un poco, accione el volante suavemente en sentido **antihorario**
3ª Para virar a la **izquierda** bastante, accione el volante fuertemente en sentido **horario**
nª ...

Evidentemente las reglas no reflejan la forma como funcionan los vehículos normales. Esto se debe a que se cometió un "error" al expresarlas, quizás por ejemplo por un signo invertido en la programación.

Nótese que un efecto equivalente se obtendría si las reglas estuviesen correctamente formuladas pero por error al ensamblar la dirección del vehículo se invirtiese su accionar.

Ahora se realizará un experimento en estas circunstancias, ordenando al sistema de control que "vire un poco a la derecha".

El controlador aplicará la 2ª regla definida previamente y accionará el volante suavemente en sentido antihorario pero en este caso el efecto obtenido distará mucho del esperado pues el vehículo virará en sentido contrario al deseado.

El mecanismo de adaptación del FMRLC iniciará el reajuste de la regla en cuestión, comparando el resultado obtenido con el que debería ser, según indique el modelo de referencia... Pero no ajustará las otras reglas en las demás zonas.

Cuando posteriormente sea necesario utilizar las otras zonas, entonces y sólo entonces, luego de obtener peligrosos resultados erróneos en cada caso, se corregirá cada regla una a una.

Nótese que pueden ser cientos de reglas (***nxm***), y para cada una tendrá que realizar «ensayos» que resultarán en virajes totalmente equivocados.

Si el controlador hubiese sido un operario humano, de manera casi natural hubiese sospechado que si la segunda regla estaba tan mal diseñada también lo estarían las demás y luego de unos pocos "virajes" inadecuados ajustaría las reglas para todas las situaciones, sin necesidad de experimentar cada una de ellas.

Este comportamiento puede asociarse con una faceta del sentido común y es la característica que se desea adicionar al FMRLC, al menos de manera aproximada.

5. EXTRAPOLADOR PARA FMRLC

El algoritmo propuesto en esta investigación consiste en aprovechar el conocimiento adquirido en cada instante, que normalmente se usaría únicamente para adaptar las reglas de la zona de operación activa para modificar también las reglas del controlador en zonas vecinas.

Se logra así una aproximación parcial al comportamiento atribuido al sentido común explicado en la sección anterior. Es parcial porque no modifica todas las reglas a partir de una extrapolación de casos particulares, sino que modifica una vecindad. Se minimiza así la posibilidad de sobregeneralizar.

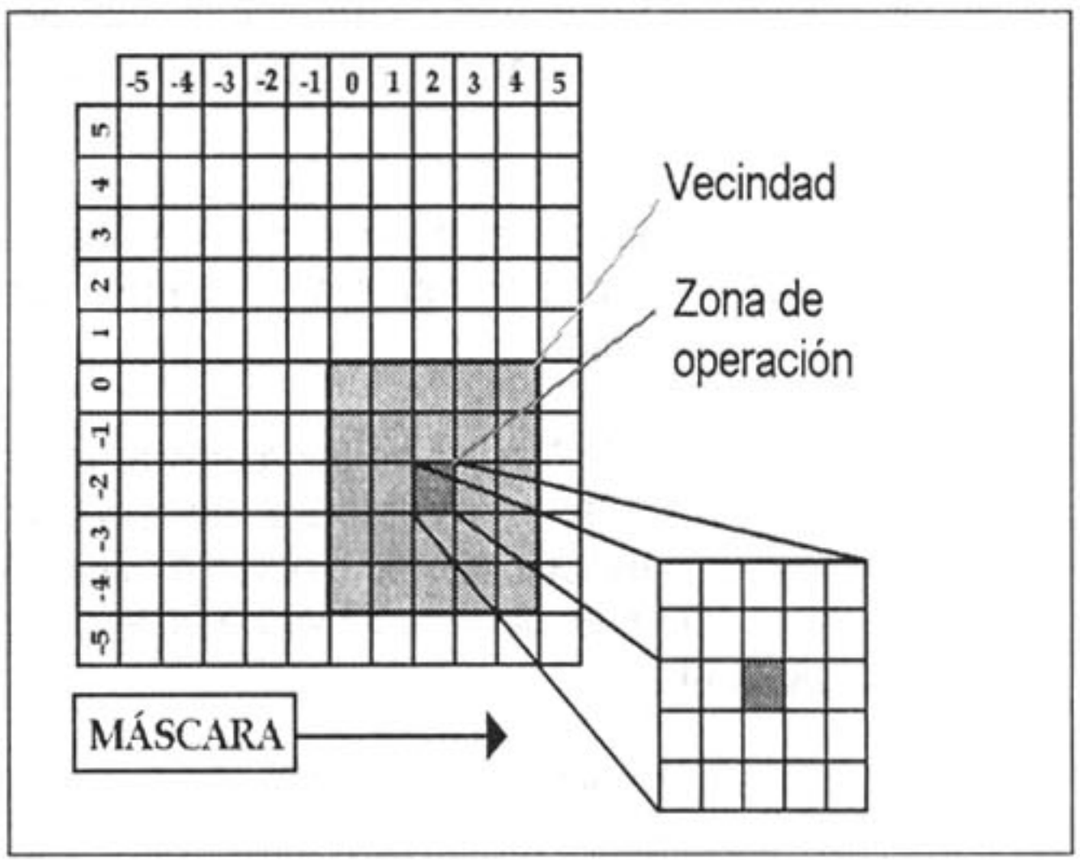


Figura 3. Extrapolación del aprendizaje mediante máscara matricial

La figura 3 ilustra el algoritmo, el cual consiste en utilizar una máscara centrada en la regla activa en el momento de la adaptación, cobijando con ella a toda la vecindad de reglas que serán modificadas por la extrapolación.

Esa máscara contiene factores en el rango (0,1] los cuales se utilizan para aplicar a cada regla bajo la máscara un ajuste proporcional al factor que coincide con ella. El factor del centro de la máscara es "1", indicando que la regla central, es decir la regla activa, será modificada en un 100% en la cantidad sugerida por el mecanismo de aprendizaje tal como sucedería si no existiese la máscara.

Las reglas vecinas se modificarán en un factor menor, y ese factor será más pequeño a medida que las reglas son más distantes respecto del centro activo. En la figura 4 se aprecian, en el eje vertical, el valor de los factores en la máscara.

El tamaño de la máscara se escogió como la mitad del rango total de cada variable cobijando así como máximo un cuarto del total de las reglas.

Esto es, que cada vez que el mecanismo de aprendizaje original modifica una regla, el nuevo mecanismo de extrapolación modifica también hasta el 25% de las reglas vecinas.

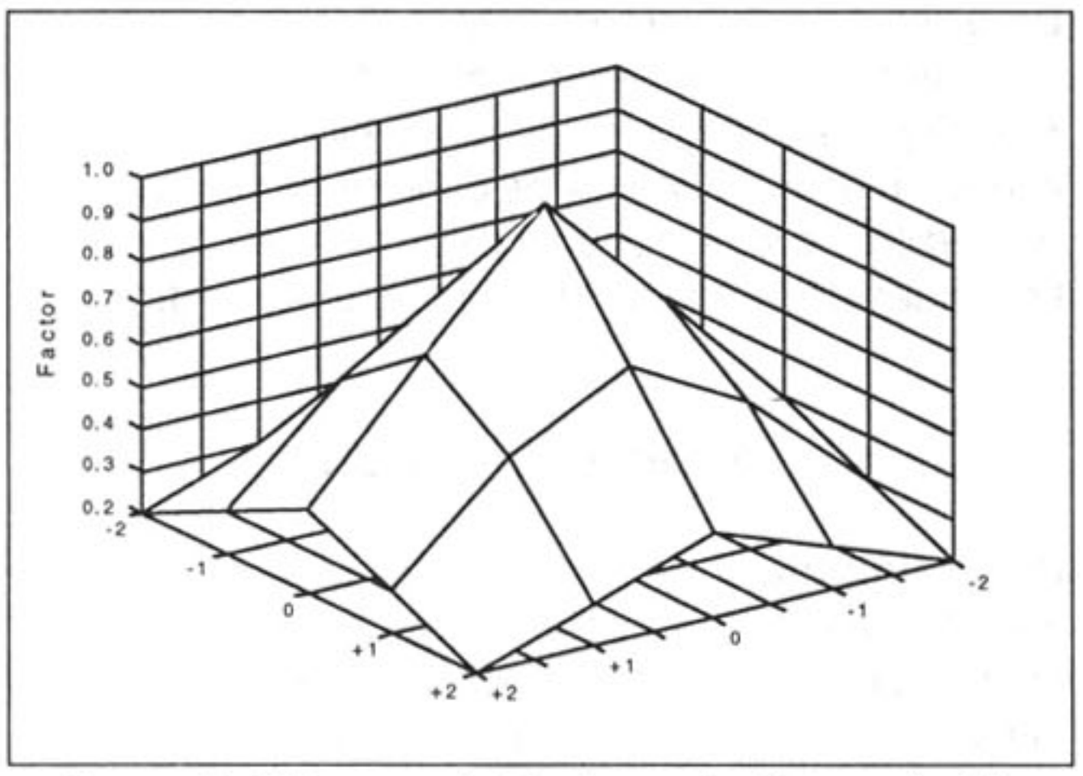


Figura 4. *Máscara de Factores de Extrapolación*

La inserción del Extrapolador del Aprendizaje en el esquema general del FMRLC se observa en la figura 5.

Nótese que adicionalmente se agregó una ganancia de robustecimiento *ga*, la cual depende de la magnitud del *error-de-referencia* *Ye*, favoreciendo la extrapolación cuando el error es grande y minimizándola cuando es pequeño.

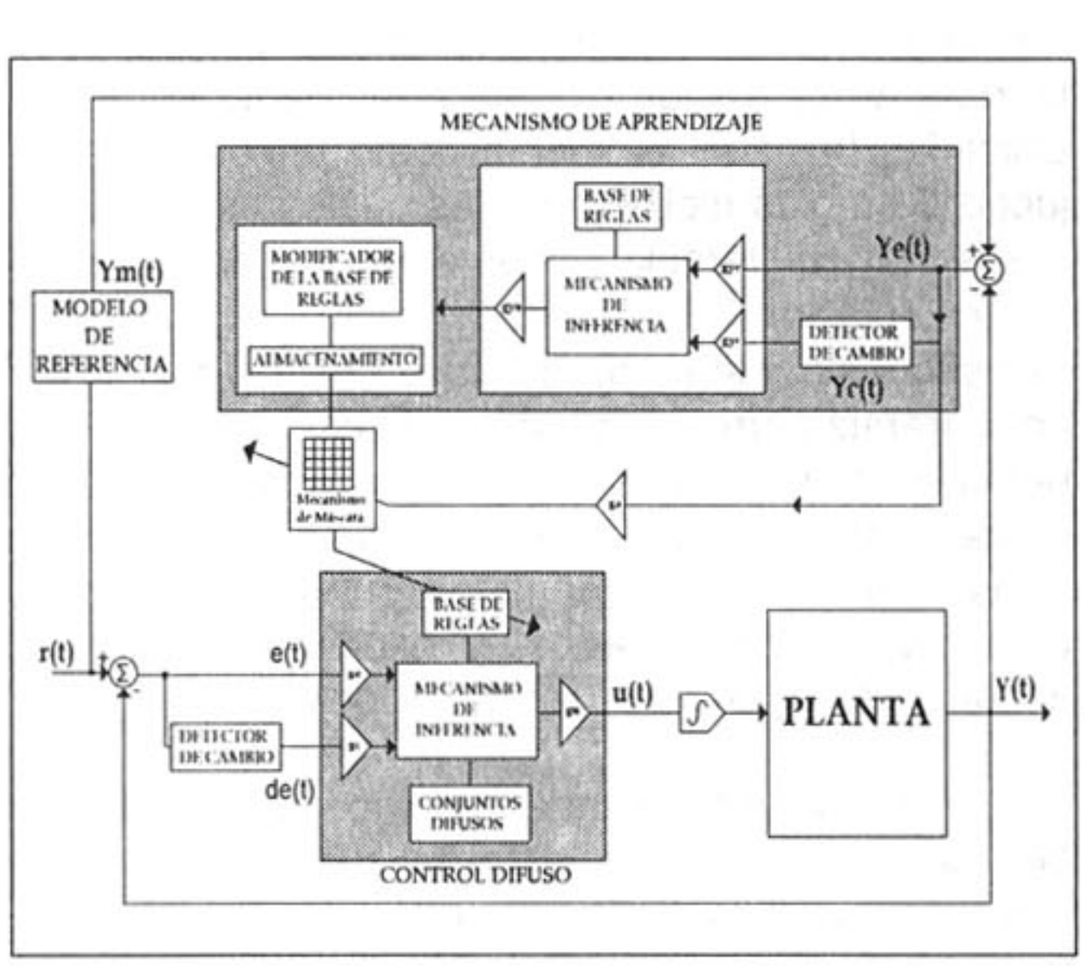


Figura 5. *Esquema del ExFMRLC*

6. EXPERIMENTOS

El código básico del algoritmo extrapolador se encuentra disponible en la referencia [3]. El programa para el experimento se elaboró usando un prototipo de interfaz de tiempo real para Matlab 5.3 desarrollada por Marisol Osorio y Carlos González [4] y se implementó en un computador personal tipo PENTIUM de 350Mhz con sistema operativo Windows 95.

Para comprobar la validez del extrapolador en situaciones prácticas y de tiempo real, con condiciones de ruido e incertidumbre no controladas, se realizaron experimentos usando un grupo motogenerador como planta a controlar. El objeto de éstos fue hacer seguimiento de una consigna de velocidad arbitraria, prestando especial atención a excitaciones tipo escalón.

El período de muestreo se escogió en 50 milisegundos. Cada prueba se realizó durante 60 segundos, equivalentes a k=1200 muestras.

Se utilizó un integrador como posprocesador del controlador difuso en virtud del modelo de la planta controlada.

Con el propósito de comparar el nuevo algoritmo con el original se definieron varios criterios de desempeño. Se evaluaron, tanto en el controlador FMRLC original como en el modificado con el Extrapolador, para tres diferentes condiciones de inicialización en cada experimento:

-*PeorSupuesto*: Reglas invertidas, erróneas. Es el caso de principal interés. Pone a prueba la idea.

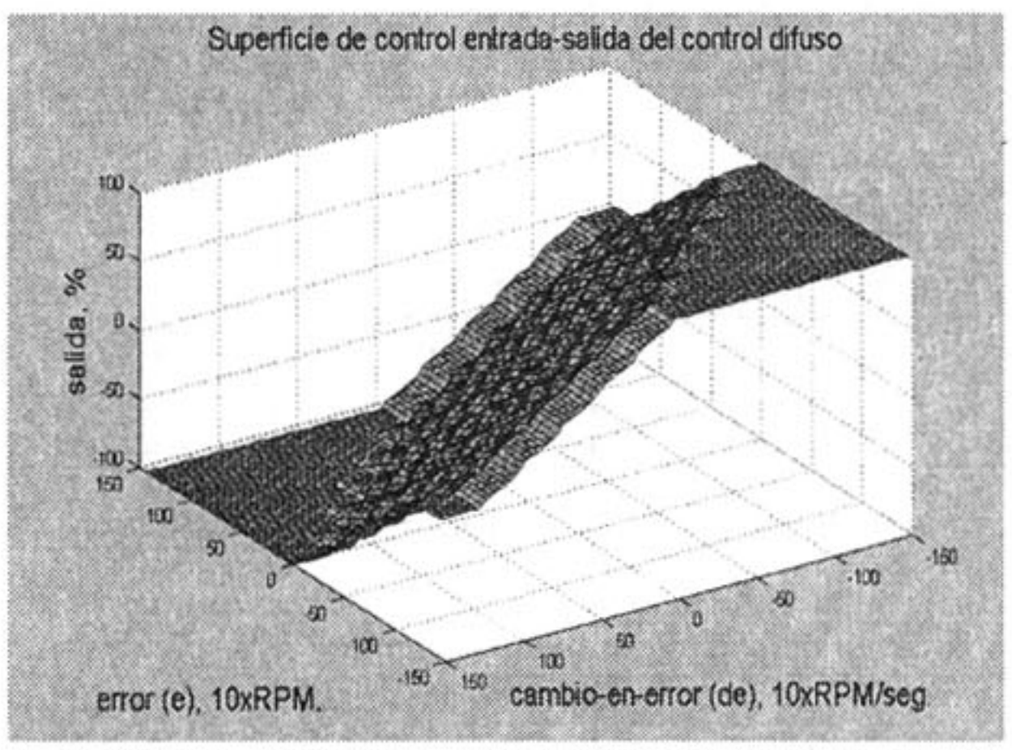


Figura 6. *Inicialización de la superficie de control asociada al PeorSupuesto. Es el inverso del MejorSupuesto.*

-*MejorSupuesto*: Reglas similares al ideal. Son el inverso del *PeorSupuesto.*

-*SinSupuesto*: Reglas Nulas. Consiste en hacer todas las reglas iguales a cero. Es equivalente a ordenarle al controlador no generar ninguna acción, haciendo caso omiso de sus entradas.

Los dos últimos casos fueron definidos para comprobar que el nuevo algoritmo no tiene efectos colaterales negativos en el funcionamiento típico del controlador.

La figura 6 representa la superficie de control generada por la base de conocimiento inicializada con el *PeorSupuesto*. Se presenta aquí para que sirva como base de comparación con las superficies de control obtenidas después de efectuado el aprendizaje al realizar los experimentos.

7.RESULTADOS

Los criterios usados para evaluar todas las pruebas son uniformes y se muestran en la Tabla 1., en la cual cada fila es un caso diferente. Las filas agrupan los resultados por condición inicial y por tipo de controlador.

Estos criterios de error en el desempeño tienen como valor ideal cero y se explican a continuación:

7.1. Criterio *Máx.Error*

Se define como el máximo EAR durante cada experimento. El EAR es el error absoluto de referencia que se presenta ante el mecanismo de aprendizaje, i.e. *velocidad-prescrita-por-el-modelo-de-referencia* ***Ym*** menos *velocidad-real-actual* ***Y***. El EAR es un indicador de la efectividad del proceso de adaptación. A medida que decrece significa que la planta se está comportando del modo propuesto en el modelo de referencia el cual es el objetivo del mecanismo de adaptación.

7.2. CECI **"Criterio de error cuadrático integral"**

Este criterio resalta los errores grandes y perdona los pequeños según una ley cuadrática. Se calcula elevando el error al cuadrado y efectuando la integral al resultado durante la duración del experimento.

7.3. CECIT **"CECI temporal"**

Como el CECI, pero además perdona los errores iniciales, y castiga los de estado estable. Se calcula elevando el error al cuadrado y multiplicándolo por el tiempo, efectuando la integral del resultado durante toda la duración del experimento.

7.4. CEAI **"Criterio de error absoluto integral"**

Este criterio castiga con proporcionalidad los errores grandes y los pequeños. Se calcula obteniendo el valor absoluto del error y efectuando la integral del resultado durante toda la duración del experimento.

7.5. CEAIT **"CEAI temporal"**

Como el CEAI pero además perdona los errores iniciales y castiga los de estado estable. Se calcula obteniendo el valor absoluto del error y multiplicándolo por el tiempo, efectuando la integral del resultado durante toda la duración del experimento.

En la tabla 1. se observa la evaluación de estos criterios del desempeño para ambos controladores ante diferentes tipos de inicialización. Se someten también a dos diferentes tipos de excitación: Senoidal y cuadrada.

Analizando las magnitudes de los criterios de desempeño en la tabla 1. se comprueba que al alimentar la base de conocimiento tanto con reglas *SinSupuesto* como *MejorSupuesto*, el controlador FMRLC original responde de manera similar ajustándolas adecuadamente tal como era de esperarse.

Sin embargo, al inicializar la base de conocimiento con reglas del tipo *PeorSupuesto* se observa un aumento de entre uno y dos órdenes de magnitud en los criterios de error, concluyendo que el FMRLC resulta incapaz de brindar un control adecuado en un tiempo razonable. En la figura 7 se constata cómo para ese caso se satura el proceso en ambos extremos de la escala.

Las saturaciones indican que luego de iniciar el experimento el motor se detuvo a pesar de que la consigna comandaba una velocidad de 1750 RPM y posteriormente el motor aceleró hasta el límite máximo de velocidad a pesar de que la consigna ya había rebajado a 850 RPM, por debajo del valor central inicial del rango de operación en 1300RPM .

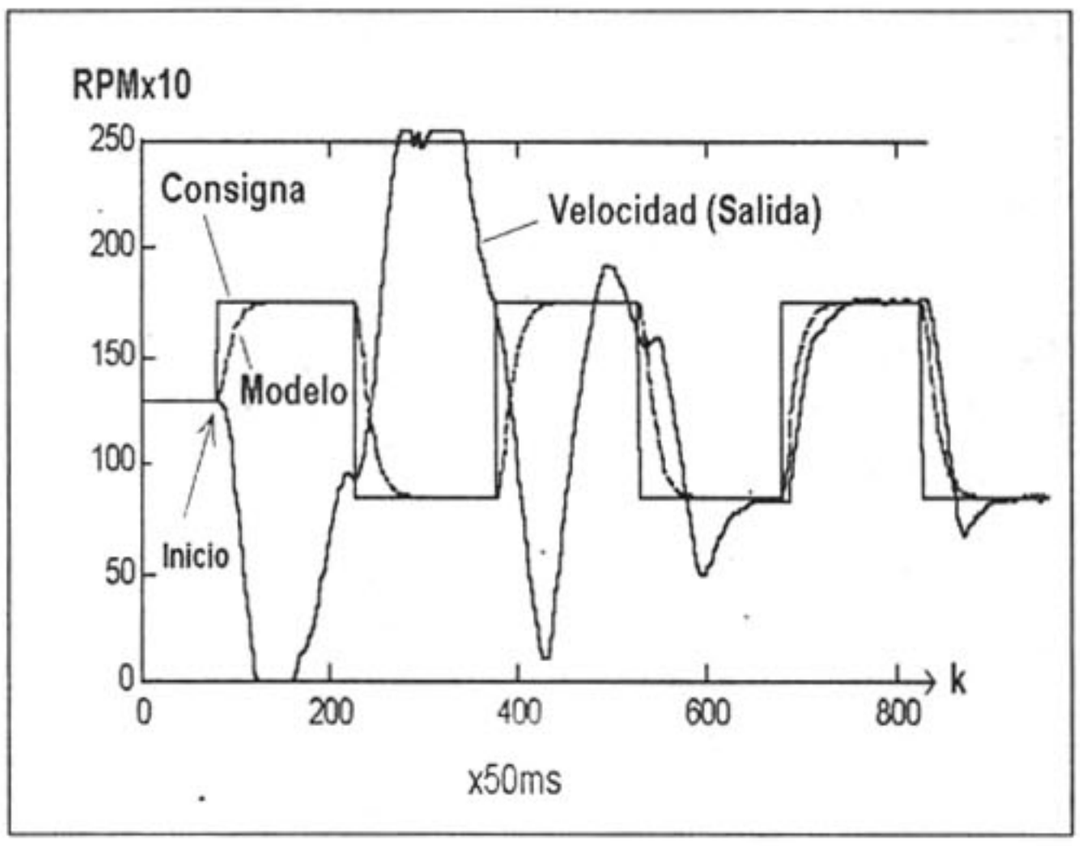


Figura 7. *Respuesta FMRLC iniciando con PeorSupuesto*

Inicialización	Tipo de Algoritmo	Max. Error		CECI		CECIT		CEAI		CEAIT	
		Sine	*Square*	*Sine*	*Square*	*Sine*	*Square*	*Sine*	*Square*	*Sine*	Square
1.	FMRLC	10	22	1718	1738	62024	44404	289	175	9734	4813
BienSupuesto	ExFMRLC	7	21	802	1055	28481	24495	193	132	6465	3153
2.	FMRLC	10	46	1465	5821	56182	102580	259	281	9150	6316
SinSupuesto	ExFMRLC	10	37	982	3164	28324	54249	208	247	6229	5205
3.	FMRLC	174	175	248800	333400	2102800	3293000	2087	2646	24799	33275
PeorSupuesto	ExFMRLC	26	65	3025	8736	71654	143330	369	435	10229	10025

Tabla 1.*Comparación de los resultados mediante criterios de error en el desempeño para diferentes consignas*

Inicialización	Tipo de Algoritmo	Max. Error		CECI		CECIT		CEAI		CEAIT		Mejora
		Sine	*Square*	*Sine*	*Square*	*Sine*	*Square*	*Sine*	*Square*	*Sine*	*Square*	Promedio
1.	FMRLC	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
BienSupuest	ExFMRLC	25%	7%	53%	39%	54%	45%	33%	24%	34%	34%	35%
2.	FMRLC	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
SinSupuesto	ExFMRLC	-5%	19%	33%	46%	50%	47%	20%	12%	32%	18%	27%
3.	FMRLC	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
PeorSupuest	ExFMRLC	85%	63%	99%	97%	97%	96%	82%	84%	59%	70%	83%

Tabla 2. *Mejora porcentual en el desempeño al usar el nuevo método propuesto (Versus Original)*

En una planta o proceso como el escogido para el experimento, la superficie de control una vez adaptada

y aprendida correctamente, debería mostrar monotonicidad y continuidad en los cambios de pendiente dentro de la zona activa de operación.

En la figura 8 se aprecia la falta de suavidad en la superficie de control aprendida lo cual es síntoma de que las reglas fueron adaptadas localmente, a veces saltando por completo zonas enteras y otras sobrecompensando algunas de ellas.

Se puede comprobar la sobrecompensación por la existencia de al menos cuatro zonas –señaladas con elipses en la figura 8- con picos de saturación superior, es decir zonas en las cuales la salida ***u*** del controlador llegará al 100%. Normalmente sólo debe existir una de dichas zonas.

Sometido a los mismo experimentos, el ExFMRLC sí pudo corregir sus reglas sin presentar nuevas saturaciones anormales, comprobando así la bondad de esta solución. Ver figuras 9 y 10.

El inicio del experimento se define en una velocidad de 1300RPM a los 4 seg. para la muestra k=80. En ese punto se aplican las reglas *PeorSupuesto*.

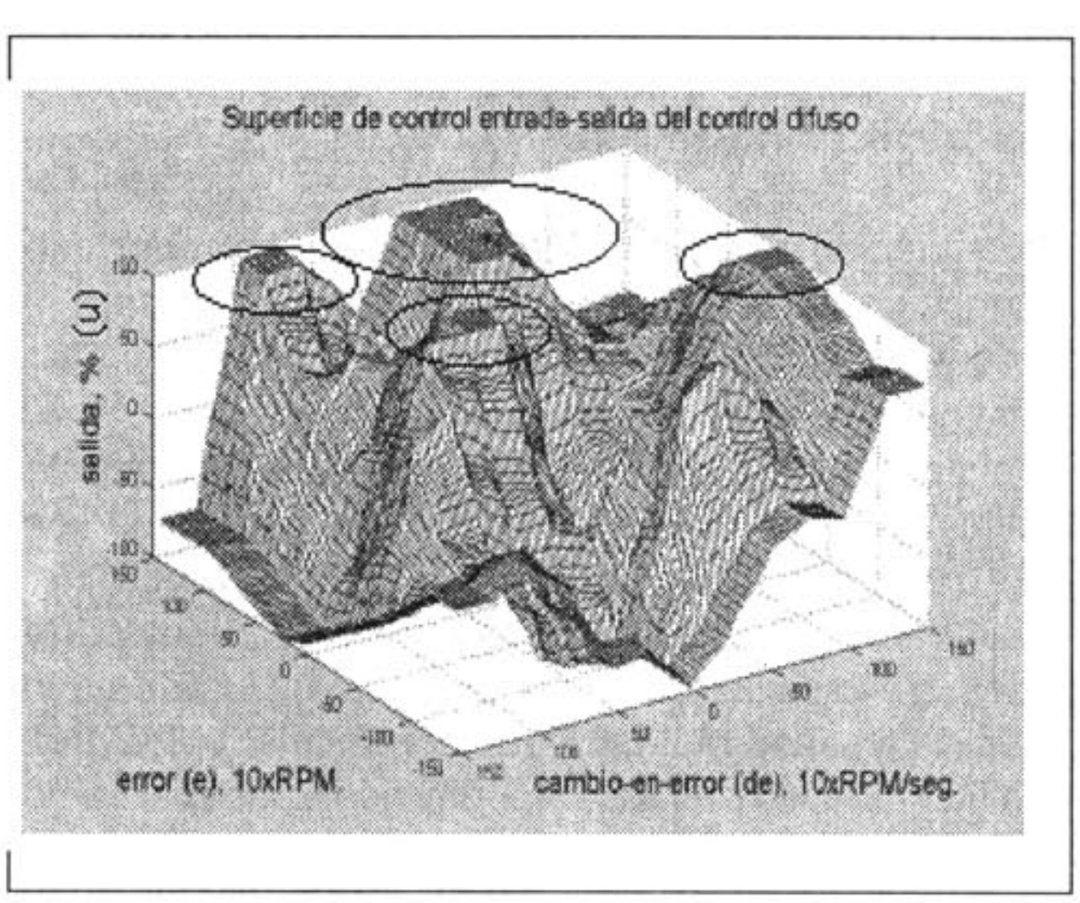


Figura 8. *Superficie final de Control FMRLC ante PeorSupuesto*

En la figura 9 se aprecia que en el punto denominado Inicio-ante el primer escalón de subida-la velocidad comienza a disminuir a pesar de que la consigna acaba de elevarse a 1750 RPM.

Esto se debe a que las reglas de inicialización le están indicando al controlador hacer todo lo contrario a lo que debería hacer y, por tanto, el resultado será también contrario.

Lo que resulta interesante en este experimento, es el hecho de que después de iniciar las acciones en sentido inverso, el mecanismo de adaptación y aprendizaje con extrapolación combinan su accionar para modificar todas las reglas vecinas a la zona de arranque, logrando invertirlas.

Una vez esto sucede, la velocidad comienza a aumentar en vez de detenerse. No se satura. Dicho efecto autocorrector no se presentaba en el FMRLC en la figura 7.

Cuando la velocidad real alcanza la consigna a 1750 RPM en el punto A, se presenta otro accionar inadecuado, permitiendo el controlador que la planta supere con un sobreimpulso la consigna

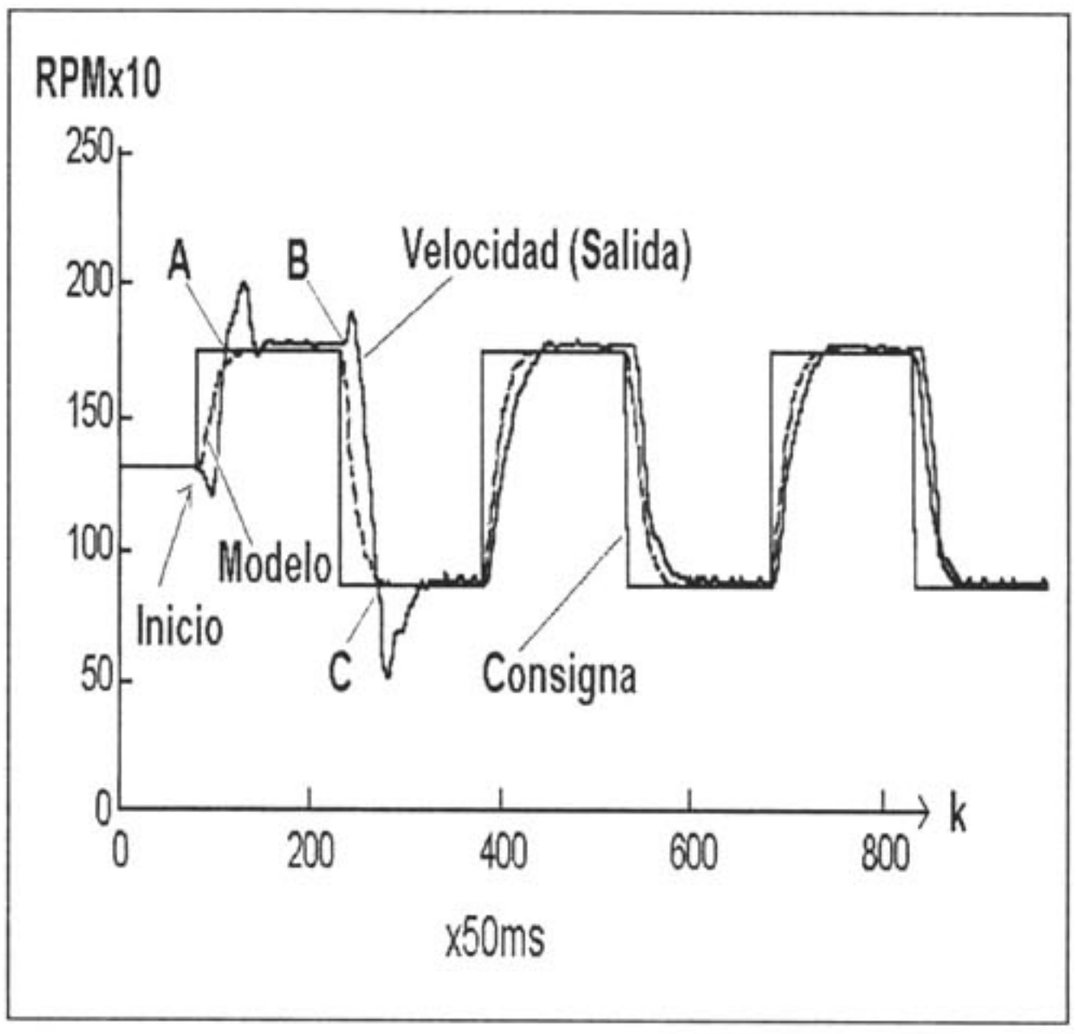


Figura 9. *Respuesta ExFMRLC iniciando con PeorSupuesto*

Esta situación es diferente a la que se dio en el arranque y por tanto aún se rige por las reglas *PeorSupuesto*. También es sorteada adecuadamente antes de saturar el sistema.

El ciclo completo se repite simétricamente en el escalón de bajada a partir del punto B, cuando la consigna cae bruscamente de 1750 a 850 RPM.
La situación en el intervalo B-C es totalmente nueva y, por tanto, para ella no se tenía aún un correcto aprendizaje. Esto a pesar de ser simétrica con la del intervalo Inicio-A.

A partir de allí, las reglas necesarias ya han sido extrapoladas, situación que se puede apreciar en la figura 10.

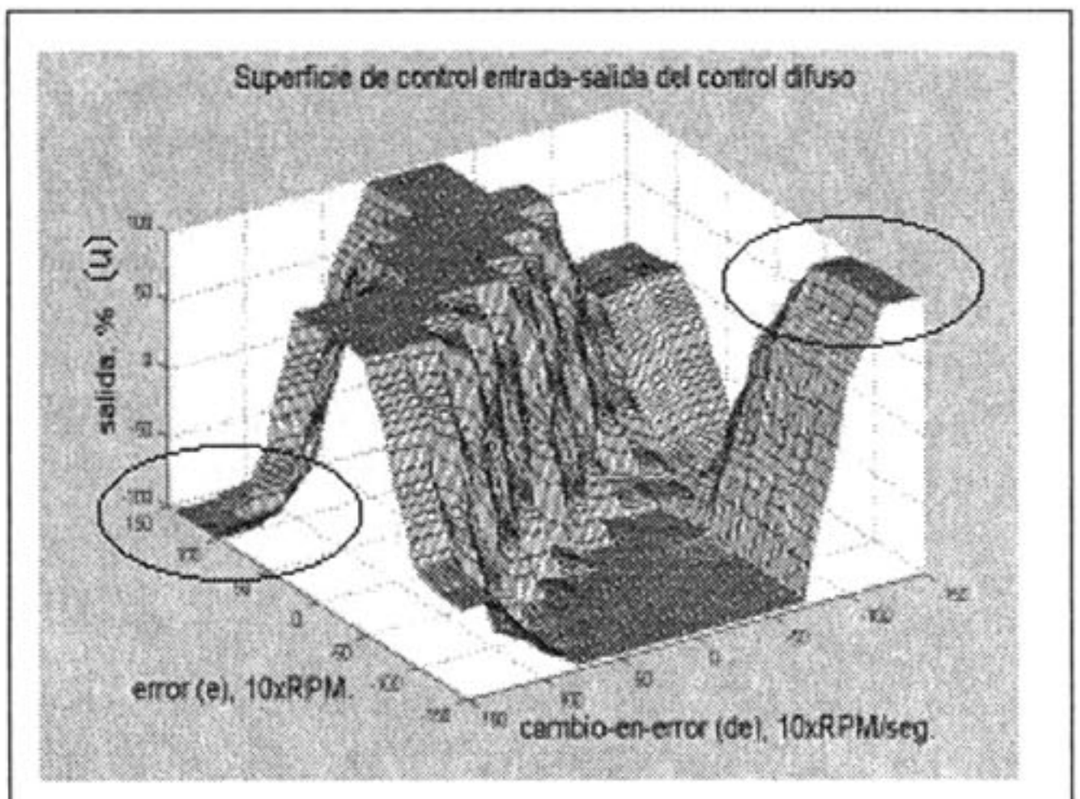


Figura 10. *Superficie final de Control ExFMRLC ante PeorSupuesto*

En la tabla 2. se presenta, a modo de balance, el porcentaje de mejora en el desempeño del controlador ExFMRLC con "sentido-común" contrastándolo contra el FMRLC original.

Se aprecia que el desempeño del ExFMRLC es en promedio un 83% mejor ante un *PeorSupuesto*, y que también presenta mejorías significativas para las otras condiciones normales de operación.

La única excepción sucede cuando el sistema se somete a una consigna senoidal luego de ser inicializado *SinSupuesto*, presentando una degradación del 5% en el *Máx.Error*, la cual no resulta significativa si se considera que todos los demás criterios presentan mejoría.

A pesar de las cifras positivas en la mejora del desempeño, al analizar con detalle la figura 10 se aprecia que no todo resultó perfecto desde el punto de vista del aprendizaje. Señaladas con óvalos se indican dos zonas de saturación anormales que aún persisten: La primera del -100%, a la extrema izquierda, para valores máximos positivos del *error e* y del *cambio-en-error de*; la segunda del 100% a la extrema derecha de la misma figura, para valores negativos mínimos de las mismas variables.

Al comparar la condición de inicialización de la figura 6 con las zonas de saturación anormales del experimento ExFMRLC en la figura 10, se aprecia que las últimas son similares, como heredadas de la primera.

Esto puede interpretarse de la siguiente forma: Las saturaciones anormales se deben a las mentiras iniciales del *PeorSupuesto*, las cuales nunca alcanzaron a ser corregidas ni por el mecanismo de adaptación ni por el algoritmo propuesto para emular el sentido común en el aprendizaje.

La falta de aprendizaje en estas zonas sugiere que el mecanismo emulador es apenas una burda aproximación al ideal del sentido común que sería deseable tener.

A pesar de haber aprendido cómo manejar la planta en la gran mayoría de las zonas de operación y de contar con la información completa para calcular la gran diferencia entre las reglas originales y las reglas adaptadas, el Mecanismo de Aprendizaje con Extrapolación no corrigió algunas de ellas. Dicho comportamiento sugiere la existencia de una limitación en el diseño del emulador del sentido común tal como está concebido, en contraste con la idea bioinspiradora original.

Una razón que explica esta situación es que, dada la rápida reacción del Mecanismo de Aprendizaje asistido por el Extrapolador en el ExFMRLC, no se exigió al controlador transitar más zonas de las estrictamente necesarias para un buen desempeño, dejando sin explorar la vecindad de aquellas que quedaron sin utilizar. De no ser así, el algoritmo emulador del sentido común les hubiese efectuado algún ajuste perceptible a las zonas no utilizadas.

Esta situación es paradójica pero puede corroborarse el concepto al comparar con las figuras 8 y 6 para el otro controlador.

Se observa que el FMRLC no guarda prácticamente vestigios del *PeorSupuesto*. Lo anterior implica que en su errado accionar durante la parte inicial del experimento el FMRLC exploró y modificó buena parte de las posibles zonas de operación. Incluso estuvo detenido y después también a máxima velocidad. Modificó todas las reglas, sí, pero no necesariamente bien.

8. CONCLUSIONES

. La implementación del algoritmo extrapolador del aprendizaje en un FMRLC mejora el desempeño del sistema controlador-planta en un 83% en promedio. Los resultados experimentales muestran que responde especialmente bien para el caso en el cual, por algún motivo, la base de conocimiento se encuentre totalmente errada. Los mismos resultados experimentales muestran que los efectos colaterales dañinos rara vez se presentan y cuando lo hacen, son despreciables.

- Se aprecia que aunque el desempeño del algoritmo se encuentra dentro de lo esperado, es susceptible de ser mejorado con la adición de ideas complementarias. Se abre así la posibilidad a nuevas investigaciones.

  En este sentido es importante investigar acerca del efecto del tamaño escogido para la vecindad afectada por la máscara de extrapolación.

  También se debe examinar el efecto de la configuración de los factores en la máscara.

- El algoritmo utilizado se inspiró en las cualidades del sentido común humano y por tanto, es razonable suponer que la misma fuente puede servir de inspiración para futuros trabajos.

- Una de las rutas sugeridas para ampliar esta línea de trabajo es buscar algoritmos que permitan extrapolar el conocimiento a toda la base de reglas en vez de limitarse a una vecindad y que puedan aprovechar las simetrías y tendencias encontradas en el comportamiento de la planta para optimizar dicha extrapolación del aprendizaje.

- Desde el punto de vista de la aplicación, la implementación experimental indica que la carga computacional impuesta al *software* por el algoritmo extrapolador no es apreciable y puede utilizarse en tiempo real para procesos que requieran muestreo del orden de decenas de milisegundos.

  Si los requerimientos fuesen más estrictos se podría implementar la solución en un lenguaje compilado en vez de usar el interpretador de Matlab lo cual aceleraría sustancialmente el proceso de cómputo.

9. BIBLIOGRAFÍA

[1.]BETANCUR, M. y ORTIZ, A., Fuzzy controller extrapolating adaptation methodology, (9°:Cali:2000). En Memorias del IX Congreso Latinoamericano de Control Automático, Cali, 2000, 1 CDROM

[2.]PASSINO, K.M. y YURKOVICH, S., Fuzzy Control. Addison Wesley. USA. 1997. 475p

[3.] Proyecto Fuzzy [en línea]. GRIAL, Mayo 2001. <http://www.upb.edu.co/grial/proyectos/fuzzy> [Consulta: 28 mayo 2001].

[4.]OSORIO, M. y GONZÁLEZ, C.E., Ambiente interactivo para trabajo experimental en tiempo real usando Matlab, (9°:Cali:2000). En Memorias del IX Congreso Latinoamericano de Control Automático, Cali, 2000, 1 CDROM

AUTORES



Manuel José Betancur Betancur.
Ingeniero Electrónico, 1987, UPB. Estudios de Maestría en Gestión Tecnológica, 1992, y de Maestría en Ingeniería, 2001, UPB. Profesor Asociado de Ingeniería Electrónica. Director del Grupo de Investigación en Automática. Universidad Pontificia Bolivariana.
Teléfono 415 9020, Medellín, Colombia
manuelb@logos.upb.edu.co

Marta Elena Pedraza Díaz.
Ingeniera Electrónica, 2001, UPB.
pedraza@cis.net.co





Diego Ignacio Marín Arango.
Ingeniero Electrónico, 2001, UPB.
Ingeniero de *Software* en I+D de CELSA S.A.
dmarin@celsa.com.co