

**IDENTIFICACIÓN Y CONTROL DE SISTEMAS ESTOCÁSTICOS CON
OBSERVACIONES INCOMPLETAS MEDIANTE MODELOS NEURO-
DIFUSOS**

AMALIA DÁVILA GÓMEZ



**INSTITUTO TECNOLÓGICO METROPOLITANO
MAESTRÍA EN AUTOMATIZACIÓN Y CONTROL INDUSTRIAL
MEDELLIN, COLOMBIA
DICIEMBRE DE 2012**

**IDENTIFICACIÓN Y CONTROL DE SISTEMAS ESTOCÁSTICOS CON
OBSERVACIONES INCOMPLETAS MEDIANTE MODELOS NEURO-
DIFUSOS**

AMALIA DÁVILA GÓMEZ

Tesis para optar el título de Magister en Automatización y Control Industrial

Directores

Prof., Edilson Delgado Trejos, PhD - ITM

Prof., Paula Andrea Ortiz Valencia, MSc - ITM

Prof., Alejandro Peña Palacio, PhD - EIA



**INSTITUTO TECNOLÓGICO METROPOLITANO
MAESTRÍA EN AUTOMATIZACIÓN Y CONTROL INDUSTRIAL
MEDELLIN, COLOMBIA
DICIEMBRE DE 2012**

**IDENTIFICACIÓN Y CONTROL DE SISTEMAS ESTOCÁSTICOS
CON OBSERVACIONES INCOMPLETAS MEDIANTE MODELOS
NEURO-DIFUSOS**

AMALIA DÁVILA GÓMEZ

A thesis submitted to the postgraduate program “Masters in Industrial Control
and Automation” in partial fulfillment of the requirements for the Master's
degree

Supervisors

Edilson Delgado Trejos, PhD - ITM
Paula Andrea Ortiz Valencia, MSc - ITM
Alejandro Peña Palacio, PhD - EIA



**INSTITUTO TECNOLÓGICO METROPOLITANO
MASTERS IN INDUSTRIAL CONTROL AND AUTOMATION
MEDELLIN, COLOMBIA
DECEMBER 2012**

DEDICATORIA

A Dios, por darme la vida y la salud, por estar conmigo en cada paso, en cada logro y por poner en mi camino las personas que quiero, que amo y que han sido mi apoyo durante este tiempo de estudio.

A mi madre Luz Dary Gómez, por su infinito amor, entrega y ternura inagotable. Porque es a quien debo mis primeras letras, mis primeros números y por supuesto mis valores.

A mi padre Abelardo Dávila, que siempre desea lo mejor para mí, me acompaña con su amor y sus oraciones de bien.

A mis hermanas, por su comprensión, su fuerza y tenacidad, y porque han sido parte importante de mi formación.

A mi novio Raúl Gómez Narváez por amarme en todo momento, por su paciencia, sus consejos y motivación constante, pero sobre todo, por ser lo más bello que ha llegado a mi vida. Te amo!

A Edilson Delgado Trejos, porque fue mi mejor maestro a lo largo de mis estudios de maestría y porque después de este trabajo es la persona que más admiro como académico y excelente director, por sus valiosos e incalculables conocimientos y la forma tan genial de transmitirlos. Por su compromiso con la academia, exigencia permanente con sus estudiantes y consigo mismo, por su entrega desinteresada, por mantenerse firme para fortalecerme en mis momentos de angustia, por cada uno de sus consejos y por supuesto, por sus regaños que me han hecho crecer profesionalmente. Es un orgullo trabajar con personas tan valiosas como usted que ponen en cada acto su sello de calidad. Gracias por creer en mí.

Amalia Dávila Gómez.

AGRADECIMIENTOS

Agradezco a mis directores de tesis, Paula Andrea Ortiz Valencia, Alejandro Peña Palacio y Edilson Delgado Trejos, por su valiosa asesoría, por todos los conocimientos compartidos conmigo y por su valioso tiempo dedicado a lo largo de este trabajo. Cada uno de sus aportes hizo posible la solución de los problemas presentados y la culminación de esta tesis de maestría.

A mis compañeros de estudio, Joe Alexander Jiménez, Miguel Becerra, Diana Alexandra Orrego, Jessid León Vélez, Martha Cecilia Guzmán, Leonardo Serna, Delio Augusto Aristizábal, Juan Gonzalo Zuluaga, María Ruth Bonilla, Ángel Gabriel Díaz, y de manera muy especial a mi compañero Juan Carlos Briñez de León con quien ahora tengo una linda amistad.

A mi amiga Claudia Victoria Quintero García, por su comprensión y acompañamiento durante este periodo de estudio.

Deseo expresar mi gratitud a la Fundación Universitaria Luis Amigó por el valioso aporte económico como apoyo a mi formación. Al Instituto Tecnológico Metropolitano (ITM) y a la Escuela de Ingeniería de Antioquia (EIA) por su financiación.

Amalia Dávila Gómez.

ÍNDICE GENERAL

GLOSARIO DE TÉRMINOS	3
LISTA DE SÍMBOLOS	6
RESUMEN.....	9
ABSTRACT.....	10
INTRODUCCIÓN	11
Objetivo general	13
Objetivos específicos	13
Organización del manuscrito.....	14
CAPÍTULO 1 REDES NEURO-DIFUSAS PARA EL CONTROL ADAPTATIVO	15
1.1 Control de sistemas estocásticos con información incompleta.....	15
1.2 Técnicas adaptativas de control	18
1.3 Redes neuro-difusas para control adaptativo	21
1.4 Sistemas estocásticos	23
1.5 Control de sistemas estocásticos mediante redes neuro-difusas	24
1.6 Recomendaciones	27
CAPÍTULO 2 MARCO EXPERIMENTAL.....	29
2.1 Descripción del sistema: Vehículos Operados Remotamente (ROV)	30
2.1.1 Notación para vehículos submarinos.....	30
2.1.2 Sistema de propulsión.....	31
2.1.3 Cinemática de un vehículo submarino.....	32
2.1.4 Posición y orientación del vehículo.....	33
2.1.5 Aceleración lineal del vehículo y su posición relativa a tierra.....	33
2.1.6 Aceleración angular y orientación del vehículo	34
2.1.7 Cálculo de la posición y la orientación del vehículo	35
2.2 Dinámica de un vehículo submarino	35
2.2.1 Movimiento traslacional	36
2.2.2 Velocidad lineal	37
2.2.3 Aceleración lineal	37
2.2.4 Ecuación de Euler.....	38
2.2.5 Tensor de inercia.	38
2.2.6 Ecuaciones dinámicas de movimiento.....	39
2.2.7 Cálculo de la matriz de coriolis y centrípeta, a partir de la matriz de masas	41
2.2.8 Fuerzas de gravedad y flotación	41
2.2.9 Fuerzas de masa añadida	44

2.2.10	Amortiguamiento hidrodinámico	47
2.2.11	Fuerzas ambientales.....	48
2.3	Modelo general del sistema	48
2.3.1	Fuerzas y torques de los propulsores.....	49
2.3.2	Fuerzas y torques de gravedad y flotación	50
2.3.3	Fuerzas y torques de amortiguamiento.....	50
2.3.4	Ecuación dinámica de movimiento	51
2.3.5	Ecuación final del modelo	52
2.4	Procedimiento propuesto	54
2.4.1	Sistemas acoplados con información incompleta.....	56
2.4.2	Estructura del modelo de identificación	57
2.4.3	Perturbación del sistema.....	63
2.4.4	Modelo de Control.....	66
2.4.5	Análisis de estabilidad en sistemas acoplados.....	67
CAPÍTULO 3 RESULTADOS Y DISCUSIÓN		69
3.1	Resultados de la identificación del sistema	69
3.2	Resultados en la reducción de perturbaciones	71
3.3	Análisis del control MADALINE.....	72
3.4	Análisis del control ANFIS.....	75
3.5	Análisis de estabilidad del sistema controlado con ANFIS	78
CAPÍTULO 4 CONCLUSIONES.....		79
CAPÍTULO 5 TRABAJO FUTURO		81
REFERENCIAS.....		82
APÉNDICE A Especificaciones técnicas del ROV		91

ÍNDICE DE FIGURAS

FIGURA 1.1.	PERSPECTIVA DE CONTROL -SISTEMAS - INFORMACIÓN INCOMPLETA...	16
FIGURA 1.2.	TÉCNICAS ADAPTATIVAS SAA Y SAMR.	20
FIGURA 1.3.	ARQUITECTURA ANFIS PARA INFERENCIA TS DE PRIMER ORDEN.....	27
FIGURA 2.1.	DIAGRAMA DE PROCESOS DE LA METODOLOGÍA PROPUESTA.....	29
FIGURA 2.2.	SISTEMAS DE COORDENADAS - DESCRIPCIÓN MATEMÁTICA DEL ROV ...	31
FIGURA 2.3.	SISTEMA DE PROPULSIÓN PARA CONDUCIR UN ROV	32
FIGURA 2.4.	TRANSFORMACIÓN RPY (<i>ROLL-PITCH-YAW</i>).....	34
FIGURA 2.5.	RELACIÓN ENTRE LOS SISTEMAS DE COORDENADAS.....	36
FIGURA 2.6.	FLUJO ALREDEDOR DEL VEHÍCULO SUBACUÁTICO.	44
FIGURA 2.7.	FUERZA Y TORQUE EJERCIDOS SOBRE EL CUERPO.....	46
FIGURA 2.8.	IMPLEMENTACIÓN DEL MODELO DE UN ROV EN MATLAB-SIMULINK.	53
FIGURA 2.9.	SEÑAL DE ENTRADA NO SINCRÓNICA A CADA ACTUADOR.	53
FIGURA 2.10.	RESPUESTA DE LAZO ABIERTO EN X (<i>SURGE</i>).	53
FIGURA 2.11.	RESPUESTA DE LAZO ABIERTO EN Y (<i>SWAY</i>).	53
FIGURA 2.12.	RESPUESTA DE LAZO ABIERTO EN Z (<i>HEAVE</i>).....	54
FIGURA 2.13.	RESPUESTA DE LAZO ABIERTO EN Φ (<i>ROLL</i>).....	54
FIGURA 2.14.	RESPUESTA DE LAZO ABIERTO EN θ (<i>PITCH</i>).....	54
FIGURA 2.15.	RESPUESTA DE LAZO ABIERTO EN Ψ (<i>YAW</i>).....	54
FIGURA 2.16.	DIAGRAMA DE LA METODOLOGÍA PROPUESTA.	55
FIGURA 2.17.	DIAGRAMAS AUTOCORRELACIÓN.	57
FIGURA 2.18.	ESTRUCTURA ANFIS PARA EL SISTEMA DE IDENTIFICACIÓN.	60
FIGURA 2.19.	CLUSTERS EN LA CAPA OCULTA IDENTIFICACIÓN ANFIS	61
FIGURA 2.20.	RUIDO ORNSTEIN-UHLENBECK	64
FIGURA 2.21.	ESTRUCTURA DEL MODELO DE CONTROL POR REFERENCIA – MRAC	66
FIGURA 3.1.	SEÑAL REAL E IDENTIFICADA PARA X (<i>SURGE</i>).....	70
FIGURA 3.2.	SEÑAL REAL E IDENTIFICADA PARA Y (<i>SWAY</i>).....	70
FIGURA 3.3.	SEÑAL REAL E IDENTIFICADA PARA Z (<i>HEAVE</i>).....	70
FIGURA 3.4.	SEÑAL REAL E IDENTIFICADA PARA Φ (<i>ROLL</i>).....	70
FIGURA 3.5.	SEÑAL REAL E IDENTIFICADA PARA θ (<i>PITCH</i>).....	71
FIGURA 3.6.	SEÑAL REAL E IDENTIFICADA PARA Ψ (<i>YAW</i>).....	71
FIGURA 3.7.	ACCIÓN DEL FILTRO EN X (<i>SURGE</i>).....	71
FIGURA 3.8.	ACCIÓN DEL FILTRO EN Y (<i>SWAY</i>).....	71
FIGURA 3.9.	ACCIÓN DEL FILTRO EN Z (<i>HEAVE</i>).....	72
FIGURA 3.10.	ACCIÓN DEL FILTRO EN Φ (<i>ROLL</i>).....	72
FIGURA 3.11.	ACCIÓN DEL FILTRO EN θ (<i>PITCH</i>).....	72
FIGURA 3.12.	ACCIÓN DEL FILTRO EN Ψ (<i>YAW</i>).....	72
FIGURA 3.13.	CONTROL MADALINE PARA SET POINT HOMOGÉNEO	73
FIGURA 3.14.	CONTROL MADALINE PARA SET POINT HETEROGÉNEO	74
FIGURA 3.15.	CONTROL MADALINE PARA SET POINT HETEROGÉNEO C.C.....	75
FIGURA 3.16.	CONTROL ANFIS PARA SET POINT HETEROGÉNEO SIN CANCELACIÓN... ..	76
FIGURA 3.17.	CONTROL ANFIS PARA SET POINT HETEROGÉNEO CON CANCELACIÓN. ..	77

ÍNDICE DE TABLAS

Tabla 2.1. Notación de los 6 grados de libertad usada para vehículos submarinos.	30
Tabla 3.1. Identificación MADALINE para cada una de las variables del ROV.	69
Tabla 3.2. Valores SNR en decibeles.	78
Tabla A.1. Plano frontal de distribución de la presión en el lugar de acción de la hélice.....	91
Tabla A.2. Momento y masa como valores de referencia.	91
Tabla A.3. Viscosidad Cinemática vs temperatura y densidad.	95
Tabla A.4. Simulación de las fuerzas de arrastre del ROV, condiciones de dominio.....	96
Tabla A.5. Torques para el movimiento <i>Yaw</i>	96

GLOSARIO DE TÉRMINOS

AFSMC	Controlador difuso adaptativo por modos deslizantes (<i>Adaptive Fuzzy Sliding Mode Controller</i>).
ANFIS	Sistema de inferencia difusa adaptable basado en una red (<i>adaptive-network-based fuzzy inference system</i>).
ANFC	Control neuro-difuso adaptativo (<i>Adaptive Neuro fuzzy Control</i>).
<i>Backpropagation</i>	Algoritmo de aprendizaje supervisado que se usa para entrenar redes neuronales artificiales, también conocido como Regla Delta Generalizada.
Backstepping	Técnica desarrollada para el diseño de los controles de estabilización para una clase especial de sistemas dinámicos no lineales.
DAC	Diagramas de autocorrelación (<i>Diagrams AutoCorrelation</i>).
DACP	Diagramas de autocorrelación parcial (<i>Diagrams Partial AutoCorrelation</i>).
DOF	Grados de libertad (<i>Degrees Of Freedom</i>).
ECG/EKG	Electrocardiograma.
FAC2	Factor de medición dentro de un factor de observaciones (<i>Within a Factor of Two</i>).
FB	Sesgo Fraccional (<i>Fractional Bias</i>)
FFU	Unidades del Filtro de Ventilación (<i>Filter Ventilation Units</i>).
FNN	Redes Neuro-difusas (<i>Fuzzy Neural Network</i>).
GDR	Regla delta generalizada (<i>Generalized Delta Rule</i>).
G-FNN	Aprendizaje genético con redes neuro-difusas (<i>Genetic-learning Neuro fuzzy Network</i>).
<i>Heave</i>	Movimiento en dirección de z .
IMRAS	Sistema Adaptativo de Referencia por Modelo Implícito (<i>Implicit Model Reference Adaptive System</i>).
IOA	Índice de Ajuste (<i>Index of Agreement</i>).
LMI	Inecuaciones lineales matriciales (<i>Linear Matrix Inequalities</i>).
LMS	Mínimos cuadrados (<i>Least-Mean-Square</i>).
LQG	Gaussiana Cuadrática Lineal (<i>Linear Quadratic Gaussian</i>).
MADALINE	Una de las primeras redes neuronales multicapa entrenable con múltiples elementos adaptivos (<i>Multiple ADaptive LINear Element</i>).

MAPE	Media del error absoluto porcentual (<i>Mean Absolute Percentage Error</i>).
MG	Media Geométrica del Sesgo (<i>Geometric Mean</i>).
MIMO	Múltiple entrada y múltiple salida (<i>Multiple-input Multiple-output</i>).
MMAC	Esquemas de Control Adaptivo de Modelo Múltiple (<i>Multiple Model Adaptive Control</i>).
MRAC	Modelo de Control de Referenciaa (<i>Model Reference Adaptive Control</i>).
MRE	Media del error relativo (<i>Mean Relative Error</i>).
NMSE	Error Cuadrático Medio Normalizado (<i>Normalized Mean Square Error</i>).
ARMA	Modelos autorregresivos de media móvil (<i>AutoRegressive Moving Average models</i>).
O-U	Proceso estocástico de <i>Ornstein Uhlenbeck</i> .
PID	Control proporcional integral derivativo (<i>Proportional Integral Derivative Controller</i>).
<i>Pitch</i>	Rotación en el eje y.
PWS	Sistema Wavelet Probabilístico (<i>Probabilistic Wavelet System</i>).
RBNN	Red Neuronal de Base Radial (<i>Radial Basis Neural Network</i>).
RGA	Algoritmo Genético de forma Reducida (<i>Reduced form Genetic Algorithm</i>).
<i>Roll</i>	Rotación en el eje x.
ROV	Vehículo operado remotamente (<i>Remotely Operated Vehicle</i>).
SAA	Sistemas Auto-Ajustables (<i>Systems Auto-Adjustable</i>).
SAMR	Sistemas Adaptativos con Modelo de Referencia (<i>Systems Adaptive with a Model Reference</i>).
SFA	Redes ANFIS con análisis de frontera estocástica (<i>Stochastic Frontier Analysis</i>).
SFNN	Red Neuronal Difusa Estocástica (<i>Stochastic Fuzzy Neural Network</i>).
SNR	Relación señal a ruido (<i>Signal to noise ratio</i>).
RIAFC	Controlador Neuro-difuso de Adaptación Indirecta basado en RGA (<i>Indirect Adaptation Neuro-fuzzy controller based on RGA</i>).
SOM	Redes de mapas auto organizativos (<i>Self Organizing Maps</i>).
STC	Esquemas de control autoajustables (<i>Self-Tuning-Control</i>).
CSTRs	Reactores con tanque agitado continuo (<i>Continuous Stirred Tank Reactors</i>).
<i>Surge</i>	Movimiento en dirección de x.
<i>Sway</i>	Movimiento en dirección de y.
TS	Takagi Sugeno.

UAPC2	Exactitud no apareada de concentración máxima (<i>Unpaired Accuracy of Peak</i>).
VG	Varianza Geométrica del Sesgo (<i>Geometric Variant</i>)
<i>Yaw</i>	Rotación en el eje z.

LISTA DE SÍMBOLOS

$\{B\}$	Sistema de coordenadas fijo al cuerpo.
$\{E\}$	Sistema de coordenadas en tierra.
K	Momentos en el eje x .
M	Momentos en el eje y .
N	Momentos en el eje z .
p	Velocidad angular en el eje x .
q	Velocidad angular en el eje y .
r	Velocidad angular en el eje z .
u	Velocidad lineal en el eje x .
v	Velocidad lineal en el eje y .
w	Velocidad lineal en el eje z .
x	Posición en x marco de referencia Inercial.
y	Posición en y marco de referencia Inercial.
z	Posición en z marco de referencia Inercial.
X	Fuerzas en el eje x .
Y	Fuerzas en el eje y .
Z	Fuerzas en el eje z .
φ	Rotación en el eje x (<i>Roll</i>).
θ	Rotación en el eje y (<i>Pitch</i>).
ψ	Rotación en el eje z (<i>Yaw</i>).
r_B	Distancia entre el punto fijo en la tierra y el centro de gravedad del submarino.
${}^E R$	Vector de posición y orientación de un vehículo respecto a un marco fijo en tierra.
${}^E r_B$	Posición del vehículo en las coordenadas x_E, y_E y z_E .
$O=(\varphi \theta \psi)^T$	Orientación del vehículo en los ángulos de Euler.
${}^E a_{EB}$	Vector de aceleración lineal del vehículo relativo a tierra representado en el sistema coordenado fijo al cuerpo.
${}^E v_{EB}$	Vector de velocidad.
${}^E \alpha_{EB}$	Vector de aceleración angular del vehículo relativo a tierra representado en el sistema coordenado fijo al cuerpo.

${}^B w_{EB}$	Relación de la velocidad angular con las derivadas en el tiempo de los ángulos de Euler.
${}^B \dot{v}$	Vector de aceleración.
${}^B v = ({}^B v_{EB}, {}^B w_{EB})^T$	Vector de velocidad.
${}^B T_B$	Fuerzas y momentos ejercidos por los propulsores.
$G(O)$	Fuerzas de flotación y gravedad.
$D({}^B v)$	Matriz de amortiguamiento.
P_E	Perturbaciones no modeladas (corrientes, etc.).
${}^B M_{RB}$	Matriz de inercia.
${}^B M_A$	Matriz de masa añadida.
${}^B C_{RB}$	Matriz de coriolis del cuerpo rígido.
${}^B C_A$	Matriz de coriolis de masa añadida.
${}^B F_A$	Fuerza debida a la masa añadida.
${}^B T_A$	Torque debido a la masa añadida.
${}^B T_B$	Vector de fuerzas y torques ejercidos sobre el cuerpo de dimensión 6×1
B	Matriz de configuración del propulsor, de dimensión $6 \times n$.
u	Cuadrados de las velocidades del propulsor.
n	Número de propulsores.
w_i	Velocidad del propulsor i .
C_{Ti}	Vector de 3×1 que contiene los parámetros de fuerza C_T en (x, y, z) para el propulsor i .
$C_{\tau i}$	Vector de 3×1 que contiene los parámetros del torque C_τ en (x, y, z) para el propulsor i .
${}^B r_i$	Vector de 3×1 que contiene la posición del propulsor i .
β_i, α_i	Son parámetros de la dinámica del propulsor.
T_i	Vector de 3×1 que contiene las fuerzas del propulsor i .
τ_i	Vector de 3×1 que contiene los torques del propulsor i .
$G = (\varphi \ \theta \ \psi)^T$	Ángulos de Euler.
${}^B F_B$	Fuerzas y torques de flotación.
${}^B F_G$	Fuerzas y torques de gravedad.
B	Magnitud de la fuerza total de flotación.
(x_b, y_b, z_b)	Centro de flotación.
W	Magnitud de la fuerza total de gravedad.

w_{EB}	Velocidad angular del vehículo.
${}^B F$	Fuerza resultante sobre el centro de gravedad del vehículo.
D	Fuerza de arrastre.
C_D	Coefficiente de arrastre.
L	Fuerza de empuje.
$D({}^B v) {}^B v$	Vector de fuerzas y torques de amortiguamiento.
D_L	Matriz de amortiguamiento lineal.
D_Q	Matriz de amortiguamiento cuadrático.
$X_u, Y_v, Z_w, K_p, M_q, N_r$	Parámetros de amortiguamiento lineal.
$X_{u u }, Y_{v v }, Z_{w w }, K_{p p }, M_{q q }, N_{r r }$	Parámetros de amortiguamiento cuadrático.
F_i	Fuerzas aplicadas al vehículo.
F_D	Fuerza de amortiguamiento hidrodinámico.
T_i	Torques aplicados al vehículo.
m	Masa del vehículo.
I_B	Matriz de momento de inercia.
${}^B I_B$	Tensor de inercia.
I_{xx}	Momento de inercia en el eje x .
I_{yy}	Momento de inercia en el eje y .
I_{zz}	Momento de inercia en el eje z .
a_{ij}	Parámetro de la masa añadida.
X_u	Coefficiente de viscosidad lineal en el eje x .
g	Aceleración debida a la gravedad.
ρ	Densidad del fluido.
${}^C a_{EC}$	Aceleración lineal del vehículo.
τ_p	Torque generado por el propulsor.
${}^B r_B$	Centro de flotación del vehículo.
T	Sustentación desarrollada por el propulsor.
${}^E \tau_B$	Torque de flotación.
${}^E f_B$	Fuerza de gravedad.

RESUMEN

En la práctica, los sistemas físicos obedecen a una dinámica multivariada e interactuante, que fácilmente es influenciada, perturbada o integrada por incertidumbres de diversas clases, las cuales inducen naturaleza estocástica al proceso global y algunas veces llegan a afectar la completitud de los datos. En esta tesis se presenta una metodología para la identificación y control de sistemas estocásticos con observaciones incompletas mediante modelos neuro-difusos. En particular, se desarrolla el análisis de la dinámica de un vehículo operado remotamente (ROV, *Remotely Operated Vehicle*) para aplicaciones submarinas, con el fin de determinar el modelo matemático y obtener simulaciones de la respuesta natural del sistema. Adicionalmente, se emplea un mecanismo de identificación del proceso mediante un modelo neuronal y otro neuro-difuso, los cuales se integran con un esquema de reducción de perturbaciones estocásticas para sobreponer las observaciones incompletas que residan en el proceso operativo. Finalmente, se propone un modelo neuro-difuso (ANFIS, *Adaptive neuro fuzzy inference system*) para controlar el sistema y se compara con el desempeño de una red neuronal con múltiples elementos *Adaline* (MADALINE, *Multiple Adaline*) con el fin de analizar las ventajas que ofrece la inclusión de conocimiento mediante reglas de inferencia difusa. Los resultados experimentales mostraron que se logró la controlabilidad del sistema llevándolo a un estado globalmente atractivo en el sentido de Lyapunov. Se pudo concluir que gracias a la capacidad de adaptación y contención de conocimiento lingüístico de los modelos neuro-difusos, el desempeño de control tuvo mayor rendimiento en términos de precisión y robustez, al compararlo con el modelo neuronal en aplicaciones operativas del ROV. Se destaca además la facilidad que tienen los modelos neuro-difusos para ser ampliamente potenciados mediante la integración de otros esquemas de procesamiento, dados los asuntos que quedaron pendientes en relación al error de estado estable y las perturbaciones ocasionadas por la interacción de los componentes.

Palabras clave – Sistemas estocásticos, información incompleta, vehículos operados remotamente, modelado de vehículos subacuáticos, modelos neuro-difusos, redes MADALINE, ANFIS, identificación y control de sistemas.

ABSTRACT

In practice, physical systems have a multivariate and coupled dynamics that can be easily influenced, disturbed or integrated by different types of uncertainties, which induce stochastic behaviour in the global process, and sometimes, the data entirety can be affected. This thesis presents a methodology for the identification and control of stochastic systems with incomplete data by means of neuro-fuzzy models. Particularly, the dynamics of a remotely operated vehicle (ROV) for underwater applications is analysed, with the aim of determining the mathematical model and obtaining simulations of its natural response. In addition, a process identification mechanism using a neural network and a neural-fuzzy model is developed, which are integrated with a stochastic disturbance reduction scheme in order to overcome the missing data difficulty involved in the system execution. Finally, an ANFIS model is proposed to control the ROV system, and it is tested the performance of a MADALINE neural network in order to analyse the advantages related to the inclusion of knowledge by means of inference rules. Experimental results showed that the proposed control scheme moved the system dynamics to a globally attractive state in the sense of Lyapunov, so the system controllability was achieved. In conclusion it can be highlighted the adaptation capability and the ability for including linguistic knowledge of the neural-fuzzy models in ROV applications, which allowed a greater performance in comparison with the neural network in terms of precision and robustness. It is important to note that the neural-fuzzy models can be easily integrated with other processing schemes in order to improve their features, in particular, for resolving pending issues related to the steady-state error and the magnitude of stochastic disturbances derived from the component interaction.

KEYWORDS – Stochastic systems, incomplete data, remotely operated vehicle, modelling of underwater vehicles, neural-fuzzy models, MADALINE networks, ANFIS, System identification and control.

INTRODUCCIÓN

Los sistemas de control centran su interés en procesos dinámicos, donde los procesos estocásticos juegan un papel importante, debido a que la mayoría de sistemas pueden llegar a tener un comportamiento inesperado y no lineal (Gao & Deng, 2009). En muchas industrias pueden existir condiciones adversas que ocasionan pérdida de información (Hossain et al., 1996) y que los sistemas embebidos adquieran naturaleza estocástica (Liu & Li, 2005), impidiendo la automatización de procesos que pueden involucrar alto riesgo para la salud de los operarios (Toola, 1993) o que incluye acciones difíciles de lograr con exactitud (Rodríguez-Gamboa et al., 2011). También puede ocurrir que el modelo del sistema actual no corresponda al inicial y esto ocasione fallas o variaciones en los procesos (Hsieh et al., 2007). Una forma de tratar estos asuntos, es recurriendo a modelos basados en redes neuronales (Del-Hoyo et al., 2009) y lógica difusa (Pehlivanoglu & Baysal, 2010) para la identificación del proceso de manera autoajustable en el tiempo, partiendo sólo de las entradas y las salidas del sistema (Baruch et al., 2008).

Uno de los aspectos más atractivos de la lógica difusa es que evita la necesidad de rigurosos modelos matemáticos basándose en el conocimiento de un experto (Sanz et al., 2011), de forma que expresiones analíticas muy complejas pueden ser remplazadas por descripciones lingüísticas auto explicadas en la estrategia de control (Novák, 2012). El éxito consiste en combinar estratégicamente las técnicas modernas de inteligencia artificial con el control tradicional (Del-Hoyo et al., 2009), puesto que la industria actual necesita sistemas de control que se autoajusten al proceso y las decisiones se basen en el comportamiento del sistema (Abhuri & Dixit, 2006). En este contexto, se ha ido incrementando el interés por los modelos neuro-difusos, y las principales razones son: *a)* El buen desempeño logrado por los algoritmos desarrollados para redes neuronales; *b)* Posibilidad de integrar el conocimiento de un experto; y *c)* Las ventajas de extraer conocimiento a partir del conjunto de datos bajo el formato de reglas (Villada et al., 2011). Dentro de las características principales de los modelos difusos está que éstos pueden ser adaptables o fijos (Marusak, 2009), y se pueden combinar fácilmente con modelos bien conocidos de aprendizaje neuronal que reportan buen desempeño, entre ellos: redes de mapas auto-organizativos (SOM), Redes de Hopfield y aprendizaje por cuantificación vectorial (LVQ) (Baruch et al., 2008). En cuanto a la combinación neuronal-difuso es muy conocido el Sistema de Inferencia Difuso Neuronal Adaptativo (ANFIS) que por contener un sistema de inferencia provee un mecanismo intuitivo y de alto nivel para representar el conocimiento mediante relaciones difusas de aprendizaje (Naderloo et al.,

2012), es decir, las expresiones no son totalmente ciertas ni totalmente falsas (Takagi & Sugeno, 1985). Aunque es conocido el buen desempeño de los modelos neuronales, difusos y neuro-difusos en aplicaciones automáticas, se presentan fuertes restricciones cuando se requiere implementar la identificación y control de un sistema cuyas perturbaciones le inducen dinámica estocástica (Zhang et al., 2008) y que por algún motivo no se cuente con todos los datos dada la dificultad de observar y seguir todos sus estados operacionales (Li & Liu, 2009).

Justificación

La mayoría de las empresas e industrias se están reestructurando a fin de operar más efectivamente en un mundo creciente y competitivo, por lo tanto están dirigiendo sus esfuerzos a la reducción de costos, al perfeccionamiento de la productividad y agilidad en sus servicios mediante la examinación exhaustiva de todos los componentes de la cadena de valor, lo que ha impactado de manera directa los procesos de producción en las empresas (Estiballo & Zamora, 2002). Para aumentar la rentabilidad, las empresas han recurrido a la automatización de sus procesos mediante el diseño de controladores automáticos. La industria requiere del desarrollo de sistemas de control cada vez más especializados para contribuir con mejores estándares de calidad en el menor tiempo posible, con menor cantidad de recursos, mayor precisión y con supervisión de forma controlada (Castellanos, 2007). El control automático resulta ser imprescindible en sistemas robóticos y reduce considerablemente la necesidad de exigencias humanas a nivel sensorial, mental, fuerza y velocidad logrando mayor productividad, precisión y agilidad en los procesos (Velásquez, 2004). La ingeniería de control ahonda en esfuerzos para identificar dinámicas complejas con difícil acceso para la toma de algunos datos o la totalidad de los mismos, perturbaciones estocásticas y condiciones adversas que no permiten llevar a cabo ciertos procesos debido a altos riesgos que pueden presentarse (Gao & Deng, 2009). Este trabajo plantea el desarrollo de un modelo neuro-difuso por adaptación para la identificación y el control de sistemas estocásticos con información incompleta, que combina la capacidad de adaptación que poseen las redes neuronales con el poder de inferencia que tiene la lógica difusa.

Problema

La problemática que envuelve el estudio de los sistemas estocásticos para su identificación y control, precisa generalmente del modelado matemático del sistema físico, así como la toma de datos y la simulación, de modo que las labores de diseño y testeo sean mucho más simples. Existen situaciones en que un sistema necesita ser controlado en condiciones que pueden cambiar de repente, y de modo arbitrario en el tiempo, y esto puede suceder gracias a cambios repentinos en el medio ambiente (e.g, control de dirección, condiciones meteorológicas cambiantes, temperatura o cambios estructurales en la planta debido a una falla, entre otros). Existen también condiciones adversas en donde es difícil la intervención para la toma de datos o seguimiento de un sistema, debido a altos riesgos, y a costos inherentes del paro de un proceso, y que en muchos casos pueden ser tan peligrosos que se puede atentar contra la salud

de las personas y la vida misma. De la revisión del estado del arte, se observa que en la literatura son escasos los modelos que permitan identificar y controlar sistemas estocásticos con observaciones incompletas, ya que este tipo de modelos requieren la combinación estratégica de las técnicas modernas de inteligencia artificial con el control tradicional (Del-Hoyo et al., 2009), para lograr sistemas de control que se autoajusten al proceso y las decisiones se basen en el comportamiento del sistema (Abhuri & Dixit, 2006), lo que implica el conocimiento de expertos, extraer conocimiento a partir del conjunto de datos bajo el formato de reglas, la aplicación de técnicas adaptativas de control y el entrenamiento de modelos neuro-difusos para la identificación y control. Sin embargo, existen dificultades para lograr el autoajuste adecuado de los parámetros de operación, puesto que los procedimientos de auto-sintonización de modelos adaptativos neuro-difusos siguen reportando problemas para la inicialización de dichos parámetros, o en algunos casos, la velocidad de aprendizaje y adaptación es muy lenta en relación con la velocidad del proceso a controlar. Visto de una manera general, se puede decir que el mal ajuste de los parámetros puede reducir la flexibilidad y la capacidad de procesamiento numérico del controlador, convirtiendo el sistema en ineficiente o redundante. En particular, si los parámetros relacionados con el número de capas ocultas o el número de reglas difusas muy grandes, se vuelve prohibitiva la implementación del sistema en tiempo real, por lo que no habría ningún interés desde la industria para este tipo de soluciones.

Hipótesis

Para dar solución al problema planteado, se propone el desarrollo de un esquema adaptativo neuro-difuso, el cual permitirá identificar y controlar las perturbaciones de naturaleza estocástica a las que está sometido un vehículo operado remotamente cuyo comportamiento es inesperado y no lineal, sin necesidad de acudir a modelos matemáticos complejos, aun cuando no se tienen completos los datos de respuesta del sistema.

Objetivo general

Proponer una metodología mediante un modelo neuro-difuso para la identificación y control de sistemas estocásticos con observaciones incompletas.

Objetivos específicos

- Analizar la dinámica de operación de un Vehículo Operado Remotamente (ROV) con el fin de determinar el modelo matemático y la respuesta natural del sistema.
- Identificar la dinámica del sistema y proponer un esquema de reducción de perturbaciones estocásticas como un mecanismo para sobreponer las observaciones incompletas.
- Proponer un modelo neuro-difuso para controlar el sistema.

Organización del manuscrito

En el capítulo 1 se presenta una revisión sobre el uso de redes neuro-difusas para el control adaptativo de sistemas estocásticos con información incompleta, en orden de determinar los campos que aún quedan abiertos en esta área del conocimiento. En el capítulo 2 se presenta la descripción matemática del sistema, algunos conceptos teóricos y una descripción detallada de la metodología propuesta. En el capítulo 3 se realiza una discusión de los resultados, y finalmente, en el capítulo 4 se presentan las conclusiones y en el capítulo 5 el trabajo futuro que queda de la tesis.

CAPÍTULO 1

REDES NEURO-DIFUSAS PARA EL CONTROL ADAPTATIVO DE SISTEMAS ESTOCÁSTICOS CON INFORMACIÓN INCOMPLETA: UNA REVISIÓN

Las redes neuro-difusas son sistemas que conjugan la capacidad de adaptación que tienen las redes neuronales con la robustez de los motores de inferencia que tiene la lógica difusa, en orden de modelar el conocimiento de expertos mediante reglas de aprendizaje, identificar dinámicas complejas y aumentar la adaptabilidad del sistema a perturbaciones que en la práctica tienden a ser de naturaleza estocástica, lo que puede provocar que la información del sistema esté incompleta. Este capítulo presenta una revisión sobre las bondades que tienen las redes neuro-difusas para el control de sistemas estocásticos con información incompleta. Se revisan las estructuras de control cuando la dinámica del sistema presenta vaguedad en los datos, la evolución de la teoría de control basada en técnicas adaptativas, y el desempeño de las redes neuro-difusas ante perturbaciones estocásticas e incertidumbre en los datos. Así, de forma preliminar se establece que el control de este tipo de sistemas debe estar compuesto por modelos híbridos soportados en rutinas de optimización y análisis probabilístico que garanticen el tratamiento de la incertidumbre sin afectar el desempeño de las estructuras de control y la consistencia en la precisión.

1.1 Control de sistemas estocásticos con información incompleta

Los sistemas estocásticos tienen un comportamiento regido por patrones que presentan resultados inesperados y variantes en el tiempo (Hossain et al., 1996). Todas las estrategias de modelado existentes y la teoría de control hacen hincapié en el aspecto de incertidumbre, porque en la medida en que un sistema se va volviendo más complejo, se hace más difícil el gobierno de su dinámica debido al incremento de las incertidumbres que provienen de diferentes variables (Li & Liu, 2009), como es el error de medición acumulada, las interacciones desconocidas entre los subsistemas, entre otras (Gao & Deng, 2009), a fin de modelar y controlar el sistema estocástico que finalmente resulta (Ushida, 2011). Aunque las incertidumbres provienen de diferentes fuentes, usualmente comparten características comunes, siendo algunas de naturaleza difusa y otras de naturaleza estocástica (Yang & Sheng, 2009). Adicionalmente a esto, es frecuente que se involucren causas como las siguientes: *a)* falta de claridad y conocimiento de los datos que surgen a partir de la modelización y/o control, *b)* vaguedad en la transmisión y procesamiento de la información (Li & Liu, 2009), *c)* vaguedad de los datos que proviene de la baja resolución de sensores o de técnicas de medición inapropiadas (Shibata, 2008), y *d)* la naturaleza estocástica del entorno que dificulta el análisis global del sistema (Gao & Deng, 2009).

La Figura 1.1 ilustra de manera general la perspectiva de control de sistemas estocásticos con información incompleta, donde se observa la importancia de un sistema de análisis de incertidumbres inherentes del proceso, o inducidas por el entorno, que puede estructurarse de rutinas probabilísticas. Asimismo, se debe incluir un sistema de representación adaptativa (e.g., computación neuronal) y un dominio lingüístico amplio y suficiente que facilite el mapeo de datos inciertos. Se propone la integración de los métodos de inteligencia computacional con procedimientos híbridos de representación, optimización y toma de decisiones en una plataforma conjunta a fin de contrarrestar la ausencia de datos y la naturaleza estocástica de las interacciones de los subsistemas.

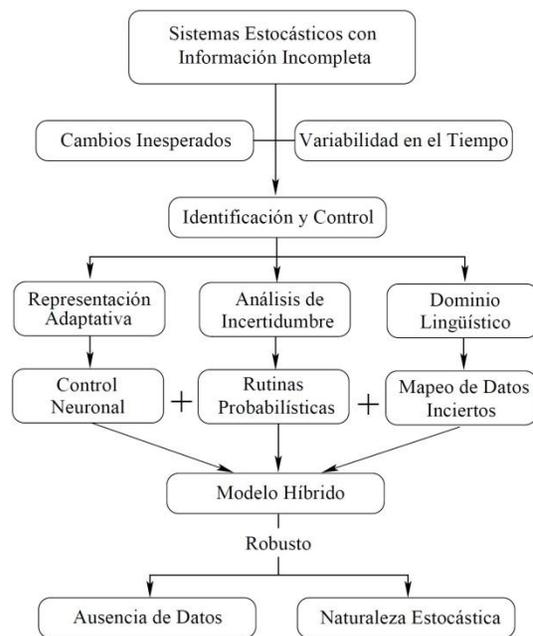


Figura 1.1. Perspectiva de control para sistemas estocásticos con información incompleta.

Fuente: Tomada de (Fossen, 1999).

La teoría de control estocástico por lo general funciona bien cuando un modelo estocástico estándar está disponible, sin embargo, esta suposición puede no ser válida en aplicaciones de procesamiento con información lingüística reducida (Mitter, 1996). Así, la teoría general de control puede mejorar el rendimiento del sistema mediante la aplicación de un modelo matemático relativamente preciso de incertidumbre (Dorato, 1987), pero limitaciones en los datos hacen difícil la tarea en aplicaciones reales cuando el comportamiento es estocástico y la información es incompleta (Li & Liu, 2009).

Existen métodos en la literatura que trabajan dinámicas de alta complejidad sobre modelos estocástico, por ejemplo, Zhou y Liu (2003) proponen un procedimiento de generación y asignación de espacios de probabilidad, luego de analizar el historial de datos. También el filtro de Kalman extendido, ampliamente usado para la estimación de ruidos aleatorios, en Xu et al (2012) es propuesto para aplicaciones de administración de energía dentro de un sistema

de redes estocásticas, sin embargo, el rendimiento de estas técnicas puede verse afectado considerablemente frente a los impactos de las incertidumbres y la información incompleta reportadas en Shibata (2008). Por otro lado, los sistemas de lógica difusa son capaces de manejar las incertidumbres mediante el mapeo de datos inciertos o el conocimiento de un dominio lingüístico, y mejorar su rendimiento a través de la computación neuronal (Li & Liu, 2008), pero su expresión lingüística no puede manejar la incertidumbre estocástica, y ambos métodos de inferencia difusa: Mamdani y Takagi Sugeno (TS) (Takagi & Sugeno, 1985), no siempre son adecuados para trabajar en un entorno estocástico con información incompleta, por lo tanto, es útil que el método de análisis estadístico y el sistema difuso estén integrados de forma híbrida en una plataforma unificada para contrarrestar las incertidumbres del proceso (Chen et al., 2010).

Desde otras perspectivas, y utilizando diferentes métodos conjugados, vale la pena mencionar otros reportes alusivos al control de sistemas estocásticos con información incompleta, como es el caso de Liu et al (2008), donde se propone un Sistema Wavelet Probabilístico (PWS, Probabilistic Wavelet System) para modelar un sistema dinámico desconocido con datos estocásticos e incompletos. El PWS usa una función wavelet novedosa de 3 dominios para hacer un balance entre probabilidad, tiempo y frecuencia, con lo cual se logra un desempeño de modelado robusto cuando la información de los datos es pobre, superando al sistema wavelet tradicional cuando el entorno de datos es estocástico e incompleto. Carravetta y Mavelli (2007) implementan un teorema de control óptimo por realimentación, el cual es una variación del teorema de Wonham. Validando sobre un sistema con información incompleta perturbado por ruido Gaussiano se obtienen soluciones más directas que aún para el caso de información completa. Adicionalmente, las ecuaciones para resolver el problema de la realimentación lineal óptima son formalmente muy similares a las que resuelven el problema de control Gaussiana Cuadrática Lineal (LQG, Linear Quadratic Gaussian) clásica. Gong (2008), por su parte, se concentra en el problema de las relaciones de preferencia difusa con información incompleta, mediante el método de mínimos cuadrados para la toma de decisiones. Usando la relación de transformación entre la relación de preferencia multiplicativa y difusa, se desarrolló un modelo de mínimo cuadrados para obtener el vector de prioridad colectiva de las relaciones de preferencia incompletas presentadas mediante máquinas de toma de decisión múltiple. Con el fin de comparar, este modelo también fue extendido a casos de preferencia difusa con información completa mediante máquinas de toma de decisión simple y múltiple, encontrándose que el método propuesto es factible y efectivo.

De acuerdo con la revisión de los trabajos mencionados en esta sección, es importante resaltar que los sistemas complejos, por sus características dinámicas, son frecuentemente controlados mediante esquemas adaptativos. Estos esquemas dependen fuertemente de la eficiencia de las técnicas de autoajuste que optimizan los parámetros del controlador. Esta es la razón por la que muchos de los esfuerzos reportados en la literatura actual están concentrados en la obtención técnicas que ofrezcan una convergencia cada vez más rápida, consistente y de mínimo costo operacional y/o computacional en términos del autoajuste de parámetros.

1.2 Técnicas adaptativas de control

La evolución de la teoría de control ha logrado el desarrollo de técnicas, tanto de identificación auto-regulable como adaptativas mediante herramientas de cómputo (Akpan & Hassapis, 2011). Las técnicas adaptativas aparecen cuando se incorporan a la máquina, de forma estructural, cualidades humanas para la toma de decisiones, y hacen referencia a un controlador cuyos parámetros son ajustados continuamente frente a los cambios en la dinámica del proceso debido a perturbaciones, de forma que puede ser de dos tipos: directo e indirecto (Stein & Saridis, 1969). La mayoría de las técnicas adaptativas de control se han aplicado como extensiones a la técnica convencional de control proporcional-integral-derivativo (PID, *proportional-integral-derivative controller*) (Tan et al., 2000). Las técnicas para la sintonización automática son derivadas del control adaptativo (Lim et al., 2012) y se desarrolló originalmente para resolver los inconvenientes surgidos a partir de procesos que cambian sus condiciones operativas con el tiempo (Hoskinson et al., 2003). En el trabajo de Gu et al (2006) se propone un esquema para el modelo de referencia de un controlador descentralizado mediante rutinas adaptativas y modos deslizantes aplicados a un sistema de múltiple entrada y múltiple salida (MIMO, *Multiple-input Multiple-output*) no lineal. El diseño se basa en la capacidad de aproximación universal que tienen los sistemas borrosos Takagi Sugeno (TS). Este enfoque no requiere conocimiento del límite superior del término de incertidumbre y, de forma analítica, el sistema de control difuso muestra ser globalmente estable en el sentido de que todas las señales implicadas están delimitadas con errores de seguimiento convergentes a cero. Los resultados de la simulación demuestran la eficacia de este enfoque. En Sánchez y Giraldo (2008) se presenta el diseño de un controlador basado en lógica difusa adaptativa y modos deslizantes, el cual es entrenado con la técnica de mínimos cuadrados recursivos, el problema de la variación de parámetros es resuelto con el controlador adaptativo y se utiliza un regulador interno PI para que el control de velocidad del motor de inducción sea realizado por medio de las corrientes de estator en vez de los voltajes. Se propone el uso del modelo del motor en el sistema de coordenadas de flujo orientado del rotor para el desarrollo y prueba del sistema de control. En Cao et al (2010) se investigó un método para mejorar la frecuencia de corrección de cristal líquido proponiendo un esquema de control concurrente en lazo abierto. Los resultados mostraron que la resolución y contraste de la imagen mejoraron significativamente por el método de control simultáneo y que el control concurrente pudo mejorar la corrección de la frecuencia de cristal líquido, demostrando que es posible controlar sistemas de varias salidas de manera simultánea mediante la aplicación de técnicas adaptativas, logrando la eficacia de ambas estructuras de control. Los esquemas adaptativos, también se han empleado en la cancelación de ruidos y procesamiento de señales periódicas y cuasi-periódicas, entre las cuales están el electrocardiograma (ECG/EKG), la cardiografía de impedancia (ZCG), los potenciales evocados cerebrales y las señales moduladas usadas en telecomunicaciones. En este sentido, Brito et al (2009) estudia el comportamiento de los pesos del algoritmo por mínimos cuadrados (LMS, *Least-Mean-Square*) para calcular los coeficientes de la transformada discreta de Fourier (DFT) de una

señal de baja frecuencia. Los resultados obtenidos son acordes con los resultados teóricos, por lo que se demuestra mediante un ejemplo que el ruido de baja frecuencia afecta la estimación de los pesos en frecuencias más altas. En Silveira et al (2012) se presenta un estudio desde dos perspectivas de adaptación sobre las estrategias de control de ajuste automático con control de varianza mínima generalizada de dos grados de libertad (GMV2DOF, *generalized minimum variance of two degrees of freedom*). El primero es desde el modelo del proceso, donde se utiliza un estimador de mínimos cuadrados con algoritmos recursivos para el diseño del autoajuste directo; y el segundo utiliza una técnica difusa Mamdani para la programación de parámetros GMV2DOF basada en interpretaciones analíticas y físicas de la robustez del sistema. Se demostró que existen ventajas en la programación difusa cuando se requiere adaptar el sistema de control a procesos desconocidos, pero cuando se trabaja con GMV2DOF y esquemas de control autoajustables (STC, *Self-tuning control*), es necesario hacer un pre-diseño que garantice la robustez y el rendimiento deseado, esto debido a que su éxito está con los sistemas lineales invariantes en el tiempo. En el trabajo de Salehi y Shahrokhi (2009), se diseña un controlador adaptativo difuso que usa la técnica *backstepping* para el control de temperatura de una clase general de reactores con tanque agitado continuo (CSTRs, *continuous stirred tank reactors*). Se utiliza lógica difusa para estimar las condiciones de concentración dependientes y otros parámetros desconocidos del sistema. Se muestra que el sistema de circuito cerrado es asintóticamente estable y el error de aproximación por perturbación externa es mínimo. El rendimiento del controlador propuesto fue probado en el control de temperatura de un reactor inestable y su efectividad fue demostrada a través de simulación por computador. Por su parte, en Che et al (2012) se presenta un modelo adaptable difuso basado en la combinación de técnicas adaptativas y redes de mapas auto-organizativos (SOM, *self-organizing maps*), también llamadas redes de Kohonen, para obtener con eficacia la predicción de carga eléctrica en términos de buena precisión e interpretabilidad al mismo tiempo. El éxito del modelo consiste en la combinación de una base de conocimiento humano, comprensible, mediante la construcción de una función de pertenencia difusa homogénea para cada subgrupo de población. Se muestra la comparación con diferentes modelos matemáticos y la eficacia es probada con datos reales donde los resultados confirman la validez del modelo propuesto en este estudio. En Yang et al (2012) se reporta un trabajo para llevar a cabo la colocación de polos dominantes a través de un procedimiento de sintonización automática basado en un Sistema Adaptativo de Referencia por Modelo Implícito (IMRAS, *Implicit Model Reference Adaptive System*). Se usa el algoritmo de Mínimos Cuadrados Recursivos (RLS) para el filtro adaptativo con el fin de estimar sus coeficientes. La validez del método propuesto fue demostrada en cuatro tipos de procesos lineales invariantes en el tiempo. Los parámetros de este controlador pudieron ser optimizados directamente sin identificar el proceso. Los resultados confirmaron que aunque otros algoritmos utilizan diferentes técnicas de autoajuste para optimizar los parámetros del controlador, con la aplicación del algoritmo RLS, se obtiene una convergencia más rápida y con parámetros ajustables. En el trabajo de (Narendra & Zhuo, 2010) se presenta un estudio donde se analizan esquemas de Control Adaptivo de Modelo Múltiple (MMAC, *Multiple*

Model Adaptive Control) y se establece que si el número de modelos es suficientemente grande y está uniformemente distribuido en el espacio de parámetros, el método ofrece una respuesta rápida y precisa. Asimismo, en este análisis se proponen procedimientos para lograr buenos resultados usando un número de modelos significativamente pequeño. Sin embargo, las aplicaciones reales en la industria, donde los sistemas dinámicos tienden a ser considerablemente complejos, exigen que el número de modelos se incremente si se quiere sostener un desempeño favorable en términos de identificación y control del proceso.

Desde hace tres décadas, se ha tenido reporte del buen impacto en procesos industriales de los Sistemas Auto-Ajustables (SAA, *Systems Auto-Adjustable*) y Sistemas Adaptativos con Modelo de Referencia (SAMR, *Systems Adaptive with a Model Reference*), los cuales son ilustrados en la Figura 1.2 (Åström, 1983).

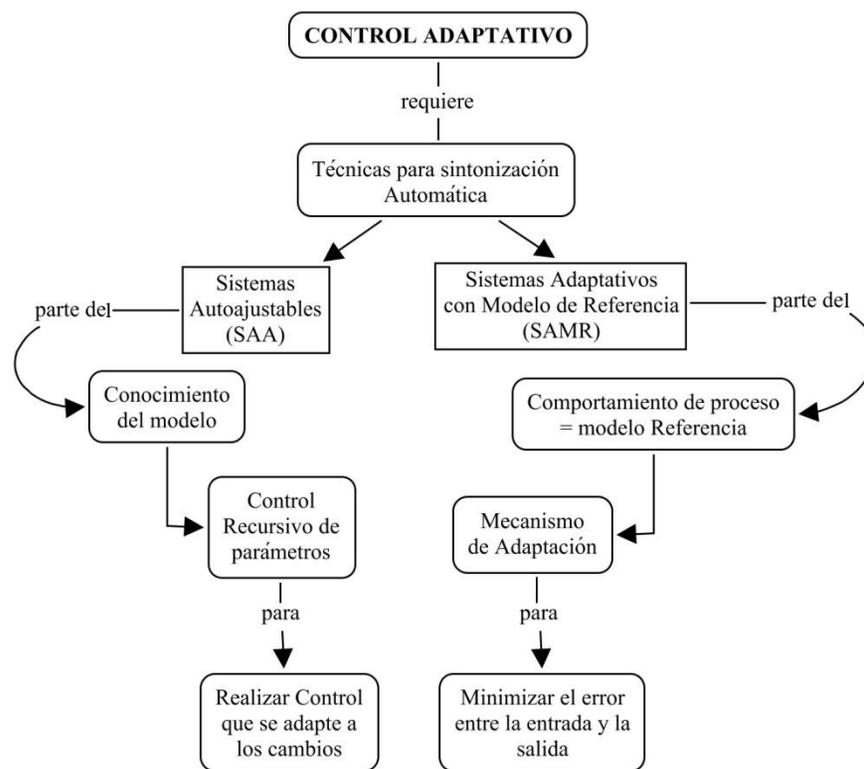


Figura 1.2. Técnicas adaptativas SAA y SAMR.
Fuente: Autores del proyecto, 2012.

El concepto sobre el que se basan los SAA fue propuesto inicialmente por Kalman (1958), y en los últimos años ha sido combinado con otros métodos de identificación basados en mínimos cuadrados recursivos, obteniendo buenos niveles de desempeño (Navia & Díaz, 2011). Asimismo, Åström y Wittenmark (1973) propusieron un SAA basado en la minimización de la varianza de salida, donde la técnica auto ajustable parte del conocimiento del modelo del proceso para realizar un control que se adapte a los cambios mediante un

procedimiento recursivo asociado a los parámetros del proceso. Sin embargo, el principal inconveniente es que la estabilidad no puede asegurarse de manera general. De otra parte, los SAMR se basan en que el comportamiento del proceso sea idéntico al modelo de referencia. Cuando existe una diferencia entre la entrada y la salida, el mecanismo de adaptación intenta minimizarla con el ajuste de los parámetros del regulador, tal y como se propone en Wang y Tang (1999). En general, se han publicado muchos trabajos bajo las técnicas SAA y SAMR, donde se ha dado preponderancia a las estrategias de control autoajustables aplicadas a sistemas lineales invariantes en el tiempo y se han propuesto diferentes híbridos con lógica difusa para el caso de sistemas no lineales e inestables (Tan et al., 2000; Wu et al., 2008).

De acuerdo con los estudios revisados en esta sección, un aspecto a considerar tiene que ver con las dificultades que tienen los modelos neuro-difusos para lograr el autoajuste adecuado de sus parámetros, puesto que los procedimientos de auto-sintonización siguen reportando problemas para la inicialización de los parámetros de operación, o en algunos casos, la velocidad de aprendizaje y adaptación es muy lenta en relación con la velocidad del proceso a controlar. Visto de una manera general, se puede decir que el mal ajuste de los parámetros puede reducir la flexibilidad y la capacidad de procesamiento numérico del controlador, convirtiendo el sistema en ineficiente o redundante. Es importante notar dentro del contexto de la aplicabilidad de los modelos neuro-difusos, la resaltable capacidad que tienen para capturar la dinámica directa e inversa de los procesos complejos, con incertidumbres y variantes en el tiempo; además de demostrar alta versatilidad y robustez para las operaciones de control. Sin embargo, en la práctica no siempre es fácil recolectar la información suficiente de un sistema complejo con incertidumbres desde el ambiente industrial de operación para la fase de entrenamiento de las redes y además es difícil contener en un conjunto reducido de expresiones lingüísticas todas las variaciones posibles de un proceso real. Por este motivo, las estrategias de entrenamiento de sistemas neuro-difusos con conjuntos reducidos y no balanceados de información, es un campo que sigue abierto en la literatura.

1.3 Redes neuro-difusas para control adaptativo

Ya es bien conocido en la literatura que las redes neuronales, debido a la capacidad de autoajuste de sus elementos procesales (i.e., neuronas) en su sistema dinámico, son capaces de estar constantemente cambiando para adaptarse a nuevas condiciones, mediante procedimientos basados en iteraciones que conforman la etapa de entrenamiento (Baruch et al., 2008; Del-Hoyo et al., 2009). Existen diferentes híbridos entre redes neuronales y lógica difusa para lograr modelos de redes neuro-difusas (FNN, *Fuzzy Neural Networ*) para control adaptativo, debido a su capacidad de combinar el razonamiento difuso con el manejo de información incierta (Han et al., 2001). Se reportan múltiples aplicaciones para controlar sistemas no lineales complejos que hacen uso de modelos neuro-difusos (Loria & Zavala-Rio, 2007). Por ejemplo, en Leu et al (1999) se presenta el diseño de sistemas neuro-difusos como un método potente que posee los méritos de bajo nivel para el aprendizaje y la potencia de cálculo de las redes neuronales, así como el pensamiento de alto nivel similar al humano junto

al razonamiento lógico de la teoría difusa. En este contexto, Hsu (2007) propone un método auto-organizativo de adaptación neuronal para un control difuso en modos deslizantes. Chen & Chen (2009) abordan el diseño y análisis de un sistema de control adaptativo neuro-difuso robusto para la sincronización de sistemas caóticos con incertidumbre en los parámetros. El sistema combina el control deslizante y el control adaptativo mediante la función de modulación tal que puede tener la ventaja de ser robusto y adaptable para hacer frente al error de aproximación. El sistema propuesto está compuesto de cuatro capas de red neuronal neuro-difusa (FNN) con identificación y un controlador de supervisión para atenuar los efectos de aproximación del error. Este estudio resuelve el problema de sincronización adaptativa mediante el método directo de Lyapunov, bajo la suposición de que el estado del sistema principal genera las trayectorias de referencia, y aunque el sistema se conoce, su dinámica es desconocida. Por otra parte, en Gao & Er (2003) se presenta un control neuro-difuso adaptativo (ANFC, *adaptive neuro-fuzzy Control*) basado en un algoritmo de aprendizaje genético con redes neuro-difusas (G-FNN, *genetic learning neuro-fuzzy network*) para la identificación y el control de un sistema no lineal con múltiples entradas y múltiples salidas (MIMO). Este controlador cuenta con las siguientes características: *a)* Estructura neuronal difusa auto-organizativa, i.e., las reglas pueden ser generadas o borradas de manera automática; *b)* Capacidad para aprender en línea en sistemas no lineales MIMO con incertidumbres; *c)* Velocidad de aprendizaje rápida; *d)* Control adaptativo; *e)* Control robusto con estabilidad global establecida según el método de Lyapunov. Así, los modelos neuro-difusos adaptativos con tasa de convergencia rápida demostraron capacidad suficiente para manejar los errores de modelado y perturbaciones externas en sistemas no lineales. Por su parte, Wang S. et al (2011) presentan un controlador difuso adaptativo por modos deslizantes (AFSMC, *adaptive fuzzy sliding mode controller*) para sistemas no lineales con incertidumbres. El sistema de lógica difusa es usado para aproximar la función del sistema desconocido y el algoritmo AFSMC es diseñado para usarse como técnica de control. De acuerdo con la teoría de Lyapunov, una función continua es diseñada para eliminar la acción del ruido de la señal de control. La simplicidad de este método facilita su implementación y el esquema de control en general garantiza la estabilidad asintótica global si todas las señales son uniformemente acotadas. Así, queda demostrado que el AFSMC alcanza mejor rendimiento que el controlador por modos deslizantes (SMC) tradicional. También en Wang Y. et al (2011) se presenta un control difuso de estructura variable por modos deslizantes (SM) con el objetivo de regular la velocidad del motor de un sistema tomado desde las Unidades del Filtro de Ventilación (FFU, *Filter Ventilation Units*), cuyas características son la no linealidad, variabilidad en el tiempo y la naturaleza multivariable compleja. Los resultados mostraron la estabilidad del control de velocidad, lo que efectivamente mejora la solidez del sistema y la respuesta transitoria del mismo. En Meharrar et al (2011) se expone un controlador basado en ANFIS, diseñado como una combinación del modelo difuso Sugeno y el algoritmo de aprendizaje *Backpropagation* para el entrenamiento de la red, mezclando así el nivel de potencia computacional de una red neuronal con el alto nivel de razonamiento de un sistema de inferencia difusa, y la capacidad de dividir los datos en grupos para adaptarse a éstos en

orden de organizar una mejor adhesión. Se demostró la viabilidad y solidez de este controlador, al analizar su respuesta rápida, exacta y potencia de rastreo. Los resultados mostraron que el modelo ANFIS tiene mejor respuesta en comparación a modelos simples de lógica difusa. En Leu et al (2009) se presenta un Controlador Neuro-difuso de Adaptación Indirecta basado en RGA (RIAFC, *Indirect Adaptation Neuro-fuzzy controller based on RGA*) para sistemas no lineales con niveles de incertidumbre, donde (RGA, *Reduced form Genetic Algorithm*) es un Algoritmo Genético de forma Reducida. Una función de ajuste es incluida en el RGA para sintonizar los parámetros en línea y evaluar la estabilidad del sistema en lazo cerrado, además de ser incorporado un controlador supervisor en el RIAFC para garantizar que los estados del sistema sean limitados a la región estable. De acuerdo con los reportes mencionados, aunque se han realizado variedad de aplicaciones en el tema de control neuro-difuso con diferentes grados de eficiencia, se puede decir que comparado con el control tradicional, el control neuro-difuso tiene dos ventajas prácticas, una es que el modelo matemático del proceso a controlar no es requerido y otra es que se obtiene un controlador no lineal desarrollado empíricamente sin complicaciones matemáticas (Landín et al., 2009).

De acuerdo con las tendencias de la literatura en sistemas de control, este tipo de sistemas puede soportarse en las bondades que ofrecen las redes neuro-difusas, en orden de asegurar el seguimiento de dinámicas pre-establecidas, dada la robustez que aportan los motores de inferencia difusa y la capacidad de adaptación que tienen las redes neuronales. En este sentido, se resaltó la tendencia actual de integrar en una plataforma conjunta los métodos de inteligencia computacional, con procedimientos híbridos de representación, optimización y toma de decisiones, en orden de contrarrestar la ausencia de datos y la naturaleza estocástica de las interacciones de los subsistemas.

1.4 Sistemas estocásticos

El primero de los procesos estocásticos tuvo su origen en el estudio de la distribución de Bernoulli, aplicada a los “paseos aleatorios o de azar”. Karl Pearson, en 1905, fue quien por vez primera resolvió este problema. En 1827, el botánico inglés Robert Brown observó que las pequeñas partículas suspendidas en un fluido inmerso siguen movimientos aleatorios (Chandrasekhar, 1954). Este fenómeno se manifiesta en los gases y se denomina movimiento browniano. La causa es porque el movimiento de las moléculas de tamaño microscópico está sometido a choques estocásticos independientes. Desde 1905 el movimiento browniano se ha tratado estadísticamente en las obras de Einstein y Smoluchowsky (Doob, 1942), contribuyendo numerosos matemáticos y físicos: Fokker, Flanck, Ornsteins, Chandrasekhar. Deduce este autor el movimiento browniano a partir del proceso de “paseos aleatorios”; lo extiende al plano y al espacio y lo relaciona con otros procesos físicos. Wiener, en 1923, demuestra la continuidad del proceso con “probabilidad uno”. Por los trabajos de Lévy también se denomina a este proceso Wiener-Lévy (1965). Los trabajos de Khitchine, Kolmogorov, Slutsky, Cramer, Karhunen, Loéve, Doob. Hanann, etc., evolucionan el

concepto de trayectoria o serie cronológica a una función aleatoria dependiendo de una variable ω estocástica. Para cada valor de esa variable se obtiene una trayectoria y todas las trayectorias imaginables representan el proceso:

$$\zeta(\omega, t) = \{\zeta(t), t \in T\}$$

Para cada $\omega = \omega_0$ la función $\zeta(\omega_0, t)$ (t variable) es una realización experimental del proceso o la serie cronológica. Y si $t = t_0$ $\zeta(t_0)$ es una variable aleatoria.

La familia de variables aleatorias -n- dimensional o vector: $\zeta = \{\zeta_1, \zeta_2, \dots, \zeta_n\}$ es un punto que pertenece a un espacio de probabilidad y es un suceso elemental. Con todos los sucesos elementales posibles se forma un espacio Ω . Un suceso estocástico es un subconjunto de Ω y pertenece a cierta clase de conjuntos de Borel \mathfrak{B}_n . Si se forman conjuntos borelianos de \mathfrak{B}_n por ejemplo, del tipo:

$$S = \{ \zeta_{t1} \leq u_1, \zeta_{t2} \leq u_2, \dots, \zeta_{tn} \leq u_n \}$$

A cada uno le corresponderá una función de distribución:

$$P(S) = F_{t_1 t_2 \dots t_n}(u_1, u_2, \dots, u_n)$$

Con su espacio de probabilidad: $(\Omega, \mathfrak{B}_n, P)$. Y se cumplen las condiciones de Kolmogorov. En este sentido una observación empírica es una realización; es decir, y siguiendo a Khintchine (1934) el proceso estocástico puede considerarse como una función abstracta del parámetro ω asignando a cada suceso elemental una función real perteneciente a Ω cada una de las cuales representa una realización. El proceso puede representarse por:

$$\{\zeta_t, t \in T\}$$

Donde T es el conjunto índice.

Las dificultades surgen, como dice Kari Karhunen (1952), cuando se analiza el proceso: si es una función medible o no; si el conjunto paramétrico T no debe restringirse al tiempo, etc. Doob fundamenta su teoría general del proceso considerándolo como una función abstracta. Finalmente Karhunen desarrolla su teoría sistemática concibiendo los “procesos como funciones cuyos valores son puntos de un espacio abstracto”.

1.5 Control de sistemas estocásticos mediante redes neuro-difusas

Las redes neuronales han sido usadas para un gran número de aplicaciones en control de sistemas con respuesta estocástica frente a determinadas condiciones de entrada, donde muchas de esas aplicaciones dependen de la estabilidad de la misma red (Ensari & Arik, 2010; Shao, 2010; Souza & Palhares, 2010; Tian & Zhou, 2010). Tomando en cuenta que los sistemas reales son generalmente afectados por una cantidad numerosa de perturbaciones externas, es muy importante considerar los efectos estocásticos para asegurar las condiciones

de estabilidad de las redes neuronales, incluyendo efectos de retardo por transmisión (Blythe et al., 2001; Huang & Cao, 2007). De otra parte, los sistemas de control automático han recibido contribuciones importantes de procedimientos basados en modelos difusos, los cuales tienen como objetivo alcanzar mejores niveles de precisión, dimensionalidad y simplicidad en la estructura de los sistemas no lineales. Comparado con los modelos matemáticos convencionales, la ventaja de los modelos difusos es la posibilidad de construirlos con la mínima cantidad de información del sistema, además de la capacidad que tienen para aproximarse a una clase amplia de sistemas no lineales (Takagi & Sugeno, 1985). Como se ha comentado en secciones anteriores, el concepto de incorporar lógica difusa dentro de una red neuronal ha crecido y se ha popularizado en los temas de investigación (Huang, 2006; Liu & Shi, 2009; Lou & Cui, 2007). Por ejemplo, se ha demostrado que ciertas entradas estocásticas podrían desestabilizar este tipo de redes, por lo que se hace muy importante analizar las propiedades de pasividad del sistema en orden de determinar los márgenes de estabilidad (Li et al., 2009; Sheng et al., 2009; Yang & Sheng, 2009). Es así que debido a la presencia de factores inevitables, tales como error de modelado, perturbaciones externas inesperadas y fluctuación de parámetros durante la implementación física, las redes neuronales implican incertidumbres derivadas de esas perturbaciones y variaciones de componentes, las cuales afectan considerablemente la pasividad del sistema completo. En este sentido, para analizar la incertidumbre de una red neuronal, un método razonable consiste en asumir y analizar parámetros por intervalos (Shu & Lam, 2008; Su & Chen, 2009). Es importante resaltar que la teoría de pasividad fue originada del análisis de circuitos y se ha convertido en una herramienta útil para analizar la estabilidad de los sistemas (Lin & Byrnes, 1995). En relación al análisis de pasividad en modelos difusos para control con redes neuronales se han reportado varios trabajos en la literatura (Liu, 2007; Liang et al., 2010; Fu et al., 2010). Por su parte, Syed-Ali & Balasubramaniam (2009) utilizan modelos TS para tratar la estabilidad global y exponencial de la incertidumbre estocástica. Mediante redes neuronales representan los modelos variables en el tiempo y a partir del enfoque Lyapunov-Krasovskii se obtienen las condiciones de estabilidad. También combinan técnicas de inecuaciones lineales matriciales (LMI, *Linear Matrix Inequalities*) y con ejemplos numéricos demuestran la exactitud de los resultados teóricos. Sin embargo, se deja abierto el caso de múltiples variables con tiempo de retardo, incluyendo tanto los retrasos discretos y distribuidos, como los criterios de estabilidad. Más adelante, Balasubramaniam y Nagamani (2012) analizan el problema de pasividad cuando existen incertidumbres en las variables estocásticas con retrasos. Se trabaja con redes neuro-difusas y se considera una función de activación generalizada que elimina el acotamiento, la monotonía y la diferenciabilidad. Se combinan los métodos de Lyapunov-Krasovskii con el método de la matriz de ponderación libre y la técnica de desigualdad. Los retrasos que dependen de las condiciones de pasividad de las redes neuronales trabajan con desigualdades matriciales lineales (LMI) mediante paquetes numéricos estándar. En general, se reportan avances importantes en relación al análisis de estabilidad. Gumus & Guneri (2009) aplican modelos neuro-difusos en cadenas de suministro con ambiente estocástico, donde se logra un pronóstico realista en relación con los costos y presupuestos, así como también se

obtiene el menor número de suministro de la cadena de valor con respecto a la demanda. Este método ofrece resultados realistas y puede ser ampliado para considerar múltiples productos con más canales de información. Pueden también ser consideradas más variables por aproximaciones neuro-difusas para lograr mayor fidelidad en el modelo. Otro caso se presenta en Chaves & Kojiri (2007), donde se desarrolla un método denominado Red Neuronal Difusa Estocástica (SFNN, *Stochastic Fuzzy Neural Network*), el cual está formado por un algoritmo genético para obtener una solución al problema de la relación entre la cantidad y la calidad del agua en un depósito, dado que no existen muchas técnicas para este tipo de optimización y aún se presentan limitaciones operativas. El SFNN se aplicó con éxito a la optimización de las estrategias operacionales mensuales teniendo en cuenta la relación de agua máxima y la calidad, mostrando mejoramientos potenciales en la calidad del agua a través de medios de control hidráulico. De otra parte, el problema de control robusto confiable para sistemas singulares no lineales con dinámica Markoviana mediante modelos difusos se estudia en Zhang (2008), donde el modelo TS es empleado para representar un sistema singular no lineal con incertidumbre en los parámetros de norma limitada. Se propuso el diseño de un controlador difuso de realimentación de estados tal que para todas las incertidumbres que se consideren aceptables, así como los casos en que el actuador falle, el sistema en lazo cerrado resultante sea robusto y estocásticamente estable. Usando la Matriz Lineal de Desigualdades (LMI), el método de función de Lyapunov estocástico es adoptado para establecer una condición suficiente de estabilidad para ecuaciones diferenciales estocásticas. Los resultados de la simulación, muestran que el método propuesto es eficaz, aunque no se contempla el análisis de estabilidad cuando se tiene el inconveniente de observaciones incompletas. Finalmente, las redes ANFIS con análisis de frontera estocástica (SFA, *Stochastic Frontier Analysis*) llamadas (ANFIS-SFA) son probadas en Azadeh et al (2011) mediante una adaptación basada en un modelo de inferencia difuso para la predicción del consumo de gas natural. Se entrenan los datos con ANFIS y se compara el error con respecto a la media del error absoluto porcentual (MAPE, *Mean Absolute Percentage Error*) para lograr un mejor rendimiento. Se usa un modelo auto-regresivo para proyectar el Producto Interno Bruto (PIB) y la población como proyección para el período 2008-2015. Estos datos proyectados se utilizan como la entrada del modelo ANFIS para predecir el consumo de gas en los países seleccionados. Este estudio resalta que el enfoque ANFIS-SFA demuestra su capacidad para manejar la complejidad, la incertidumbre y el azar en un sistema estocástico.

Esta revisión permite apreciar que el éxito logrado por los modelos neuro-difusos se debe a su capacidad de auto ajuste y facilidad para adoptar comportamientos nuevos frente a condiciones de incertidumbre, como también a su habilidad para obtener el modelo matemático, siendo más usados y más conocidos en el control estocástico, los modelos ANFIS. El modelo ANFIS fue propuesto por Jang (1992), y consiste en un sistema híbrido neuro-difuso, funcionalmente equivalente al mecanismo de inferencia (Takagi & Sugeno, 1985). En cuanto a los modelos T-S de primer orden, estos obedecen a un conjunto de reglas difusas SI-ENTONCES, donde todos los nodos de una misma capa tienen la misma función.

En este modelo los nodos representados con cuadros son nodos adaptables, es decir, sus parámetros son ajustables. En la Figura 1.3, se observa la estructura de la red ANFIS, esta es una red adaptativa que permite la aplicación de la topología de la red neuronal, junto con la lógica difusa. La primera capa representa la capa de pertenencia, en la segunda capa cada nodo se multiplica con las próximas señales y las salidas. Cada nodo de salida en esta capa representa la fuerza de disparo de una regla, la tercera capa actúa como normalizador, la cuarta capa calcula la salida y por último, el único nodo en la quinta capa se encarga de combinar todas las salidas en una (Hayati et al., 2010). La red neuronal obtenida se comporta (funcionalmente) exactamente como un sistema tipo Sugeno. Las capas permiten intuir ventajas relacionadas con el enorme potencial en aplicaciones de control estocástico para sistemas con información incompleta. Entre las principales ventajas, se pueden destacar la flexibilidad y robustez, en tareas que exijan el desarrollo de soluciones en el marco de una fácil implementación. Sin embargo, muchos campos quedan abiertos en aspectos relacionados con la optimización de la topología del modelo o del mismo proceso de entrenamiento (Jang, 1993).

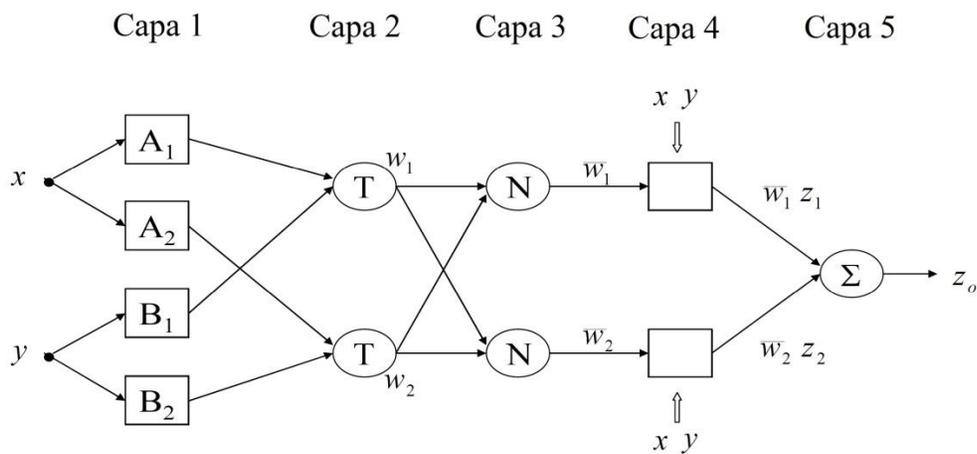


Figura 1.3. Arquitectura ANFIS equivalente para inferencia TS de primer orden.
Fuente: Tomada de (Hayati et al., 2010).

1.6 Recomendaciones

En la práctica, se ha vuelto frecuente encontrar sistemas cuyo entorno de operación induce fuertes perturbaciones de naturaleza estocástica, resultando afectada de manera considerable la observabilidad de todos los estados. El control de este tipo de sistemas con información incompleta puede soportarse en las bondades que ofrecen las redes neuro-difusas, las cuales son reportadas en la literatura como un método amplio y suficiente para asegurar el seguimiento de dinámicas pre-establecidas, aprovechando la robustez que aportan los motores de inferencia difusa y la capacidad de adaptación que tienen las redes neuronales.

En este capítulo se presentó una revisión del control de sistemas estocásticos con información incompleta, donde se observa la existencia de diferentes métodos que permiten el modelado

estocástico, sin embargo, también se observa que aún hacen falta modelos que permitan mejorar el manejo de la incertidumbre cuando no se cuenta con la totalidad de los datos. De otra parte, se presenta un análisis de las técnicas adaptativas de control más utilizadas en la literatura, y se identifica que la mayoría de técnicas son en alguna medida derivaciones o extensiones del esquema de control convencional PID, donde predominan las aplicaciones híbridas por modos deslizantes. Debido a que estos esquemas dependen fuertemente de la eficiencia de las técnicas de autoajuste que optimizan los parámetros del controlador, se percibe la necesidad de aumentar los esfuerzos investigativos en función de lograr mejores técnicas de autoajuste que permitan la implementación en tiempo real del esquema adaptativo de control sin comprometer los niveles de precisión y robustez. Adicionalmente, se presentó una revisión de redes neuro-difusas para control adaptativo y se puede apreciar que la mayor bondad de estas redes es su capacidad de auto ajuste, gracias a sus elementos procesales y su sistema dinámico que le permite cambiar y adoptar nuevos comportamientos frente a diferentes condiciones, aún dadas por el azar. Frente al control convencional, se tiene la ventaja de evitar modelos matemáticos complejos, además de alcanzar altos niveles de precisión, dimensionalidad y simplicidad. Asimismo, se pudo observar en la literatura que los modelos neuro-difusos más usados y mejor conocidos para el control estocástico se basan en el modelo ANFIS (Hayati et al., 2010).

Finalmente, al momento de considerar un sistema estocástico con información incompleta, como es el caso de los vehículos operados remotamente para aplicaciones submarinas (Shim et al., 2010), donde son inciertas todas las perturbaciones que el ambiente le puede inducir al sistema (Azisa et al., 2012), es importante que el control esté compuesto por modelos híbridos que permitan combinar las ventajas neuro-difusas con métodos probabilísticos y evolutivos, a fin de lograr estructuras de control adaptativas que garanticen el tratamiento adecuado de las incertidumbres en ambientes de naturaleza estocástica sin afectar la precisión y consistencia en los resultados.

CAPÍTULO 2

MARCO EXPERIMENTAL

Para el desarrollo de esta tesis se ha elegido como sistema de análisis un vehículo operado remotamente para aplicaciones submarinas, por ser un sistema de naturaleza estocástica dada la incertidumbre de las perturbaciones que le induce el ambiente, y que por condiciones adversas de operación, no se asegura que se tenga información completa de sus datos. Las primeras implementaciones de control para este sistema fueron propuestas por Fossen y Sagatun (1991) en términos de los ángulos de Euler (Javadi-Moghaddam & Bagheri, 2010), sin embargo se sigue promoviendo las investigaciones para mejorar la robustez del control, puesto que se carece de modelos que permitan el tratamiento de la incertidumbre cuando no se cuenta con la totalidad de los datos. Esto impulsa a la necesidad de investigar nuevas estrategias que resulten de la integración, en una plataforma conjunta, de métodos de inteligencia computacional con procedimientos híbridos de representación, optimización y toma de decisiones, a fin de contrarrestar la ausencia de datos y la naturaleza estocástica de las interacciones de los subsistemas. En este capítulo se realiza una descripción detallada del modelo teórico y el marco experimental para la identificación y control de este sistema estocástico con información incompleta mediante modelos neuro-difusos. La Figura 2.1 muestra el proceso de la metodología propuesta.

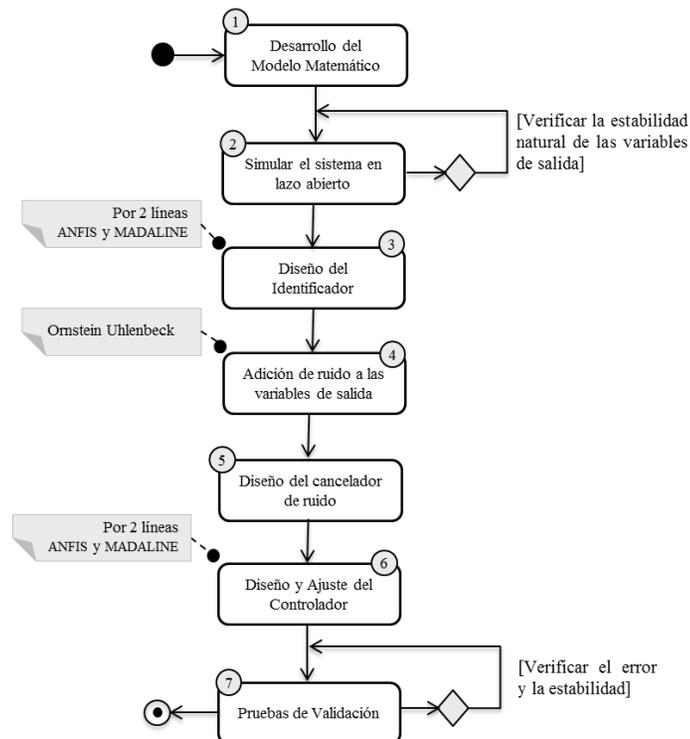


Figura 2.1. Diagrama de procesos de la metodología propuesta.

Fuente: Autores del proyecto, 2013.

2.1 Descripción del sistema: Vehículos Operados Remotamente (ROV)

Este trabajo de investigación está enfocado a un sistema de control adaptativo neuro-difuso, que se basa en un modelo de base radial para el control y seguimiento de un vehículo operado remotamente (ROV), a fin de conseguir un nivel de precisión respecto a la posición de sus 6 grados de libertad. En muchas aplicaciones, los ROVs necesitan ser controlables desde la superficie y maniobrar frente a objetos desde cualquier punto, aunque es conocido que la dinámica de un ROV es altamente no lineal y variante en el tiempo. En este trabajo se emplea la capacidad de aprendizaje para hacer frente a la incertidumbre paramétrica y la perturbación se maneja ajustando los parámetros por medio de la inferencia difusa. Para la identificación se hace necesario organizar los datos de las entradas en una base de datos, definir los elementos de la estructura del modelo, ingresar dato a dato a la red neuronal de base radial (RBNN, Radial Basis Neural Network) y actualizar los pesos mediante la regla delta generalizada (GDR, *Generalized Delta Rule*). Por medio de la misma red neuronal se asegura la estabilidad del sistema, implementando un control de tipo adaptativo para que el ROV sea capaz de hacer observaciones submarinas y rastrear un objeto en una ruta predefinida incluso cuando este es afectado por diferentes perturbaciones que intervienen en sus movimientos bajo el agua. Se consideran algunas propiedades que son inherentes al ROV, como parámetros acotados del sistema, perturbaciones inducidas y propiedades antisimétricas. Asimismo, se utilizan las ecuaciones cinemáticas y dinámicas que describen el movimiento de un cuerpo rígido y las ecuaciones hidrodinámicas principales que afectan su movimiento a través del agua.

2.1.1 Notación para vehículos submarinos

Existe una notación internacional usada en vehículos submarinos respecto a su posición, orientación, velocidad y fuerza de sus 6 grados de libertad tal como se muestra en la Tabla 2.1 (Fossen, 1994). Esta notación es relativa a los sistemas de coordenadas fijos en el cuerpo del vehículo $\{B\}$ y fijos en tierra $\{E\}$.

Grados de libertad	Movimientos y Rotaciones	Fuerzas y Momentos	Velocidad Lineal y Angular	Posición y Ángulos de Euler
1	Movimiento en dirección de x (<i>surge</i>)	X	u	x
2	Movimiento en dirección de y (<i>sway</i>)	Y	v	y
3	Movimiento en dirección de z (<i>heave</i>)	Z	w	z
4	Rotación en el eje x (<i>roll</i>)	K	p	ϕ
5	Rotación en el eje y (<i>pitch</i>)	M	q	θ
6	Rotación en el eje z (<i>yaw</i>)	N	r	Ψ

Tabla 2.1. Notación de los 6 grados de libertad usada para vehículos submarinos.

Fuente: Tomada de (Fossen, 1999).

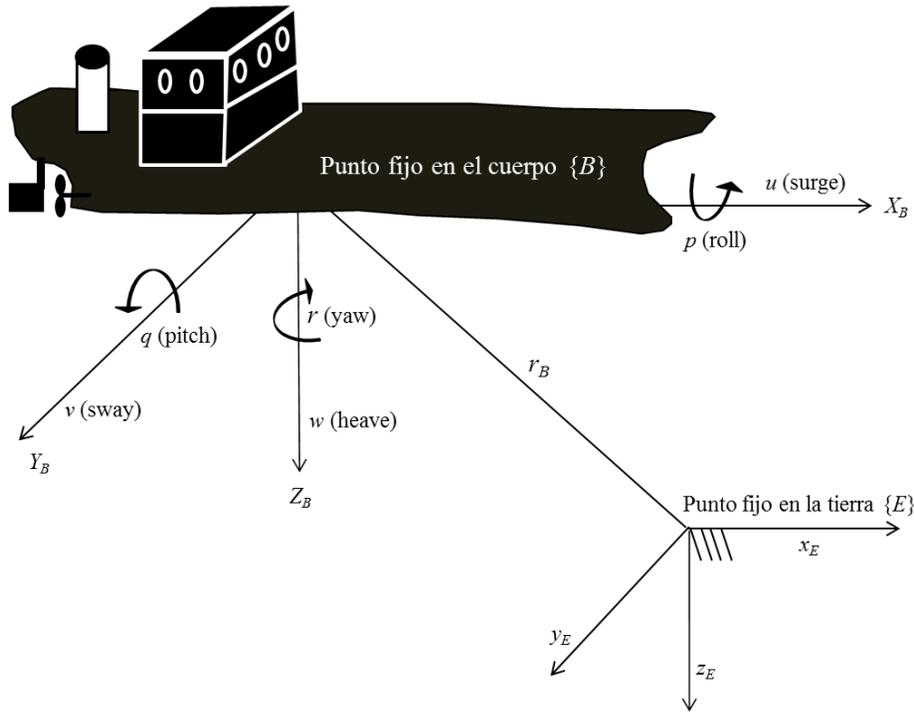


Figura 2.2. Sistemas de coordenadas usadas en la descripción matemática del ROV.
Fuente: Tomada de (Fossen, 1999).

De acuerdo con la Figura 2.2, el *yaw* (r) representa el movimiento angular hacia los lados, *surge* (u) los movimientos lineales hacia adelante y atrás, *sway* (v) el movimiento lineal hacia los lados, *heave* (w) el movimiento lineal hacia abajo y hacia arriba, *pitch* (q) es el movimiento angular de picada y de subida, el *roll* (p) es el movimiento angular de balanceo y volcamiento, y r_B es la distancia entre el punto fijo en la tierra y el centro de gravedad del submarino.

2.1.2 Sistema de propulsión

El sistema de propulsión para conducir el ROV requiere de 4 propulsores (T_{x1} , T_{x2}) para sus movimientos horizontales hacia adelante y hacia atrás y (T_{z1} , T_{z2}) para el movimiento vertical hacia abajo y hacia arriba como se observa en la Figura 2.3. Se puede instalar un quinto propulsor adicional para ayudar al vehículo en su movimiento lineal hacia los lados (T_y). El movimiento angular hacia los lados depende de la diferencia que ejercen los dos ejes de las propelas. Las especificaciones físicas de las propelas y el ROV se presentan en el Apéndice A.

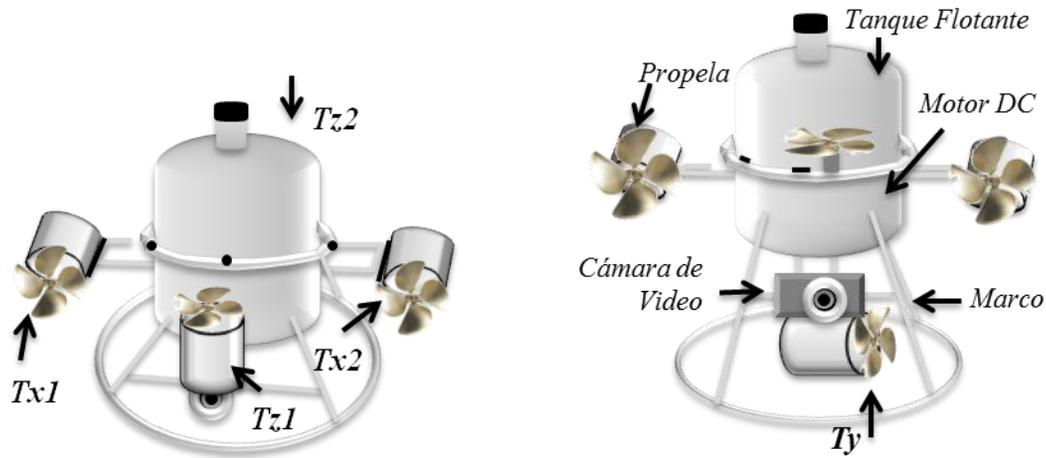


Figura 2.3. Sistema de propulsión para conducir un ROV en sus movimientos horizontales.
Fuente: Tomada de (Javadi et al., 2010).

2.1.3 Cinemática de un vehículo submarino

La cinemática estudia la posición, velocidad, aceleración y todas las derivadas de orden superior de las variables de posición, con respecto al tiempo o a otra variable. El estudio de la cinemática para un ROV, permite expresar la posición, velocidad y orientación del vehículo respecto a un marco de referencia fijo en tierra.

Para obtener la dinámica del modelo, es importante establecer las siguientes consideraciones:

1. El vehículo se mueve a baja velocidad.
2. Las fuerzas de amortiguación no están acopladas. Esto quiere decir que las variables que alimentan la matriz de amortiguamiento del sistema se toman como linealmente independientes, y en sentido práctico significa que el movimiento del ROV a velocidades bajas no es apreciablemente afectado por el amortiguamiento del entorno.
3. Los términos lineales de las fuerzas de amortiguamiento se asumen despreciables. Teniendo en cuenta que la fuerza de amortiguamiento hidrodinámico se compone de los términos cuadráticos de la fuerza de sustentación y los términos lineales de la fuerza de fricción. Si tenemos en cuenta la primera consideración y la segunda, entonces es lógico que se pueda asumir que la fricción es depreciable.
4. El centro de gravedad y el centro de flotación es el mismo.
5. Todos los coeficientes hidrodinámicos son constantes.
6. la literatura sugiere que las variables angulares debidas al Pitch y al Roll son estables de forma natural.

La dinámica de los vehículos submarinos es altamente no lineal, así como su variabilidad en el tiempo, la naturaleza incierta de sus parámetros y la dificultad para obtener los valores exactos de los coeficientes hidrodinámicos. Por otro lado, las perturbaciones generadas a partir de las

corrientes de las olas, son muy difíciles de modelar, por lo tanto, las perturbaciones serán descritas matemáticamente utilizando una función periódica $E_m(t)$. Las aceleraciones angular y lineal del vehículo son necesarias para conocer la posición y la orientación relativas a tierra. En este estudio, se presentan las ecuaciones de movimiento de un vehículo submarino, donde las aceleraciones se deben a las fuerzas que actúan sobre el vehículo, y la sumatoria de las fuerzas y de los torques generan una fuerza resultante. En general, se considera un modelo no lineal de seis grados de libertad sobre la base descrita por Fossen en sus trabajos para vehículos bajo el agua (Fossen, 1994; Yuh, 1990).

2.1.4 Posición y orientación del vehículo

De aquí en adelante en todo el documento la notación de este capítulo, el hiperíndice a la izquierda indica las coordenadas que pueden ser fijo a tierra $\{E\}$ o fijo en el cuerpo del vehículo $\{B\}$.

La posición y orientación de un vehículo relativo a un sistema coordenado fijo en tierra se puede representar por el vector ${}^E R$

$${}^E R = \begin{pmatrix} {}^E r_B \\ O \end{pmatrix} \begin{pmatrix} x \\ y \\ z \\ \varphi \\ \theta \\ \psi \end{pmatrix} \quad (2.1)$$

Todas las notaciones consignadas en la expresión (2.1) están descritas en la Tabla 2.1 y ${}^E r_B$ hace referencia a la posición del vehículo en las coordenadas x_E, y_E y z_E y, de igual manera, O se refiere a la orientación del vehículo en los ángulos de Euler.

2.1.5 Aceleración lineal del vehículo y su posición relativa a tierra

Conociendo el vector de aceleración lineal del vehículo relativo a tierra representado en el sistema coordenado fijo al cuerpo ${}^E a_{EB}$, y conociendo los ángulos φ, θ y ψ , se puede calcular el vector de aceleración lineal representado en el sistema coordenado fijo a tierra. Para esta relación, se deben realizar 3 rotaciones básicas relativas de $\{B\}$ a $\{E\}$, como se muestra en la Figura 2.4 y se describe a continuación:

- $\{1\}$ es el sistema coordenado $\{E\}$ después de ser rotado sobre z_E un ángulo ψ .
- $\{2\}$ es el sistema coordenado $\{1\}$ después de ser rotado sobre y_1 un ángulo θ .
- $\{B\}$ es el sistema coordenado $\{2\}$ después de ser rotado sobre x_2 un ángulo φ .

De una manera más formal, puede expresarse así:

$${}^E a_{EB} = {}^E R_1 {}^1 R_2 {}^2 R_B \Rightarrow {}^B a_{EB} {}^E R_B = \text{Rot}(\psi, z) \text{Rot}(\theta, y) \text{Rot}(\varphi, x) \Rightarrow$$

$${}^E a_{EB} = \begin{pmatrix} \cos\psi\cos\theta & -\sin\psi\cos\theta + \cos\psi\sin\theta\sin\varphi & \sin\psi\sin\theta + \cos\psi\cos\theta\sin\varphi \\ \sin\psi\cos\theta & \cos\psi\cos\theta + \sin\psi\sin\theta\sin\varphi & -\cos\psi\sin\theta + \sin\psi\cos\theta\sin\varphi \\ -\sin\theta & \cos\theta\sin\varphi & \cos\theta\cos\varphi \end{pmatrix} \quad (2.2)$$

Una vez calculada ${}^E a_{EB}$ con técnicas simples de integración se puede obtener la velocidad ${}^E v_{EB}$ y la posición ${}^E r_B$ en el sistema coordenado fijo a tierra.

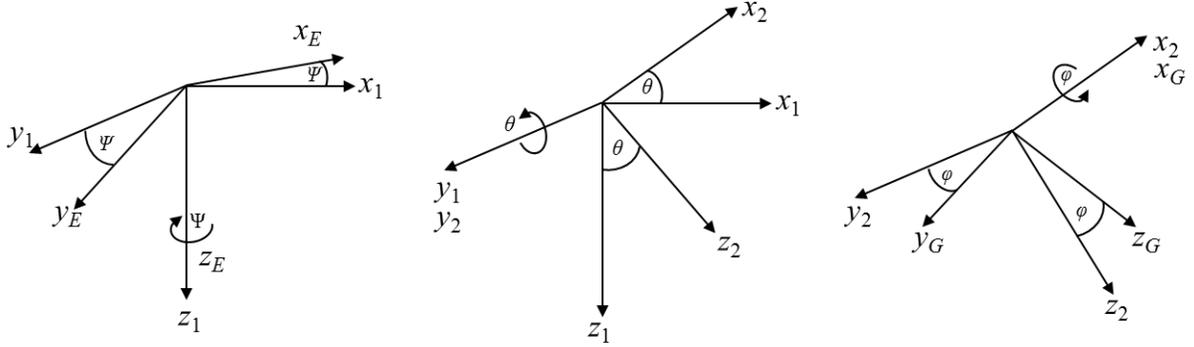


Figura 2.4. Transformación RPY (*Roll-Pitch-Yaw*).
Fuente: Tomada de (Fossen, 1999).

2.1.6 Aceleración angular y orientación del vehículo

Conociendo los ángulos φ , θ y ψ , y el vector de aceleración angular del vehículo relativo a tierra representado en el sistema coordenado fijo al cuerpo ${}^E \alpha_{EB}$, se pueden calcular las derivadas en el tiempo de los ángulos de Euler $\dot{\varphi}$, $\dot{\theta}$ y $\dot{\psi}$ como una función del tiempo. Lo que permite interpretar la evolución de la orientación del vehículo como una función del tiempo.

La velocidad angular se calcula con la siguiente expresión:

$${}^B \omega_{EB} = \int ({}^E \alpha_{EB}) dt \quad (2.3)$$

La relación de la velocidad angular con las derivadas en el tiempo de los ángulos de Euler se determina así:

$${}^B ({}^E \omega_B) = \begin{pmatrix} \dot{\varphi} \\ 0 \\ 0 \end{pmatrix} + {}^B R_2 \begin{pmatrix} 0 \\ \dot{\theta} \\ 0 \end{pmatrix} + {}^B R_1 \begin{pmatrix} 0 \\ 0 \\ \dot{\psi} \end{pmatrix} \quad (2.4)$$

$${}^B ({}^E \omega_B) = \begin{pmatrix} \dot{\varphi} \\ 0 \\ 0 \end{pmatrix} + ({}^B R_2)^T \begin{pmatrix} 0 \\ \dot{\theta} \\ 0 \end{pmatrix} + ({}^B R_1)^T \begin{pmatrix} 0 \\ 0 \\ \dot{\psi} \end{pmatrix} \quad (2.5)$$

$${}^B ({}^E \omega_B) = \begin{pmatrix} \dot{\varphi} \\ 0 \\ 0 \end{pmatrix} + (\text{Rot}(\varphi, x))^T \begin{pmatrix} 0 \\ \dot{\theta} \\ 0 \end{pmatrix} + (\text{Rot}(\varphi, y)\text{Rot}(\varphi, x))^T \begin{pmatrix} 0 \\ 0 \\ \dot{\psi} \end{pmatrix} \quad (2.6)$$

$${}^B({}^E w_B) = \begin{pmatrix} \dot{\varphi} \\ 0 \\ 0 \end{pmatrix} + \begin{pmatrix} 1 & 0 & 0 \\ 0 & \cos \varphi & \sin \varphi \\ 0 & -\sin \varphi & \cos \varphi \end{pmatrix} \begin{pmatrix} \dot{\theta} \\ 0 \\ 0 \end{pmatrix} + \begin{pmatrix} 1 & 0 & 0 \\ 0 & \cos \varphi & \sin \varphi \\ 0 & -\sin \varphi & \cos \varphi \end{pmatrix} \begin{pmatrix} \cos \theta & 0 & -\sin \theta \\ 0 & 1 & 0 \\ \sin \theta & 0 & \cos \theta \end{pmatrix} \begin{pmatrix} 0 \\ 0 \\ \dot{\psi} \end{pmatrix} \quad (2.7)$$

$$\begin{pmatrix} \dot{\varphi} - \sin \theta \dot{\psi} \\ \cos \varphi \dot{\theta} + \sin \varphi \cos \theta \dot{\psi} \\ -\sin \varphi \dot{\theta} + \cos \varphi \cos \theta \dot{\psi} \end{pmatrix} = \begin{pmatrix} 1 & 0 & -\sin \theta \\ 0 & \cos \varphi & \sin \varphi \cos \theta \\ 0 & -\sin \varphi & \cos \varphi \cos \theta \end{pmatrix} \begin{pmatrix} \dot{\varphi} \\ \dot{\theta} \\ \dot{\psi} \end{pmatrix} \quad (2.8)$$

$$T(O)\dot{O} = {}^E w_{EB} \Rightarrow \dot{O} = T(O)^{-1} {}^E w_{EB} \quad (2.9)$$

Ahora, al calcular la matriz inversa de transformación $T(O)^{-1}$, se obtiene:

$$T(O)^{-1} = \begin{pmatrix} 1 & \sin \varphi \tan \theta & \cos \varphi \tan \theta \\ 0 & \cos \varphi & -\sin \varphi \\ 0 & \frac{\sin \varphi}{\cos \theta} & \frac{\cos \varphi}{\cos \theta} \end{pmatrix} \quad (2.10)$$

2.1.7 Cálculo de la posición y la orientación del vehículo

Usando ${}^B a_{EB}$ y ${}^B \alpha_{EB}$ como vectores conocidos que representan las aceleraciones lineal y angular relativas al sistema coordenado fijo en el cuerpo del vehículo, la orientación y posición del vehículo se obtiene con las siguientes ecuaciones:

$${}^B v_{EB} = \int {}^B (a_{EB}) dt \quad (2.11)$$

$${}^B w_{EB} = \int {}^B (\alpha_{EB}) dt \quad (2.12)$$

$$\begin{pmatrix} \dot{r}_B \\ \dot{O} \end{pmatrix} + \begin{pmatrix} {}^E R_B & O_{3 \times 3} \\ O_{3 \times 3} & T(O)^{-1} \end{pmatrix} \begin{pmatrix} v_{EB} \\ w_{EB} \end{pmatrix} \quad (2.13)$$

2.2 Dinámica de un vehículo submarino

En la cinemática del vehículo es necesario conocer la aceleración causada por la fuerza y torque resultante. Sabiendo que la aceleración es la segunda derivada de la posición, se pueden representar como vectores tanto la aceleración como la posición, de forma que:

Si ${}^B r = (x, y, z)^T$ es un vector representado en $\{B\}$ y $\{B\}$ es un sistema trasladado y rotado a partir de un sistema $\{A\}$, y ${}^A r_B$ es el origen de $\{B\}$ representado en $\{A\}$, entonces, se puede derivar el vector relativo a este marco, derivando cada componente del vector de la siguiente manera:

$$\frac{d^B}{dt} {}^B r = {}^B \dot{r} = {}^B (\dot{x}\dot{y}\dot{z}) \quad (2.14)$$

Luego el vector resultante es entonces representado en relación al mismo marco $\{B\}$ o relativo a otro marco diferente, lo cual puede expresarse así:

$${}^B \left(\frac{d^A B_r}{dt} \right) = {}^A R_B \frac{d^B B_r}{dt} + {}^A w_{ABX} {}^A R_B B_r \quad (2.15)$$

$${}^B \left(\frac{d^A B_r}{dt} \right) = \frac{d^B B_r}{dt} + {}^B w_{ABX} B_r \quad (2.16)$$

En el primer caso el vector resultante es representado en el marco de derivación. En el segundo caso, la representación es en el mismo marco del vector diferenciado.

2.2.1 Movimiento traslacional

La segunda ley de Newton relaciona la fuerza ejercida sobre un cuerpo con la aceleración lineal provocada, lo cual puede expresarse de la forma:

$$\left. \begin{aligned} F &= \frac{d}{dt} P \\ P &= m \cdot v \end{aligned} \right\} \Rightarrow F = m \cdot a \quad (2.17)$$

En concordancia con la Figura 2.5, ${}^B F$ es la fuerza resultante que actúa sobre el centro de gravedad del vehículo y m_B es la masa del vehículo, entonces la aceleración lineal ejercida sobre éste, ${}^c a_{EC}$, es calculada aplicando la ecuación (2.17).

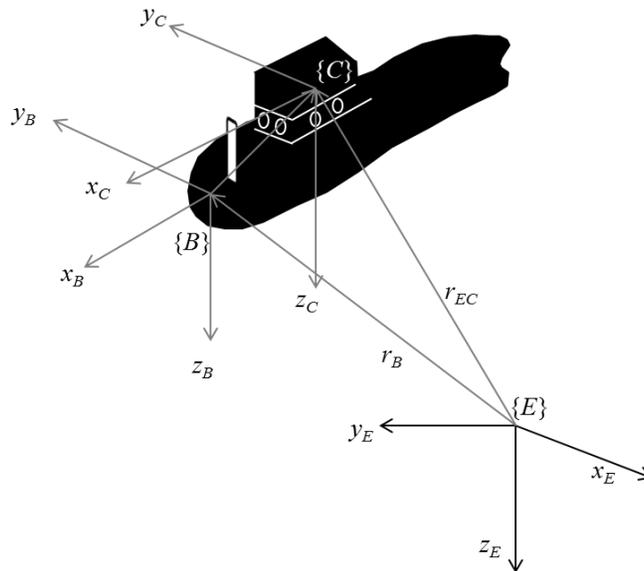


Figura 2.5. Relación entre los sistemas de coordenadas.
Fuente: Tomada de (Fossen, 1999)

2.2.2 Velocidad lineal

La velocidad del centro de gravedad de un vehículo se expresa como:

$${}^E v_{EC} = \frac{d^E}{dt} {}^E r_C \quad (2.18)$$

Sustituyendo (2.15) en (2.18) se tiene:

$${}^E v_{EC} = \frac{d^E}{dt} {}^E r_B + {}^E R_B \frac{d^B}{dt} {}^B r_C + {}^E w_{EBx} {}^E R_B {}^B r_C \quad (2.19)$$

$${}^E v_{EC} = {}^E \dot{r}_B + {}^E R_B {}^B \dot{r}_C + {}^E w_{EBx} {}^E R_B {}^B r_C \quad (2.20)$$

Como la posición del centro de gravedad relativa a $\{B\}$ se mantiene constante, su derivada es cero, por lo tanto:

$${}^E v_{EC} = {}^E v_{EB} + {}^E w_{EBx} + {}^E r_{EB} \quad (2.21)$$

2.2.3 Aceleración lineal

La aceleración lineal es calculada como la derivada del vector de la velocidad, así:

$$\left. \begin{aligned} {}^E a_{EC} &= \frac{d^E}{dt} {}^E v_{EC} \\ {}^E v_{EC} &= {}^E v_{EB} + {}^E w_{EBx} {}^E R_B {}^B r_C \end{aligned} \right\} \Rightarrow {}^E a_{EC} = \frac{d^E}{dt} ({}^E v_{EB} + {}^E w_{EBx} {}^E R_B {}^B r_C) \Rightarrow$$

$${}^E a_{EC} = {}^E \dot{v}_{EB} + \frac{d^E}{dt} ({}^E w_{EBx} {}^E R_B {}^B r_C) \Rightarrow$$

$$\left. \begin{aligned} {}^E a_{EC} &= {}^E \dot{v}_{EB} + \left(\frac{d^E}{dt} {}^E w_{EBx} {}^E R_B {}^B r_C \right) + \left({}^E w_{EBx} \frac{d^E}{dt} {}^E R_B {}^B r_C \right) \\ \frac{d^E}{dt} {}^E R_B {}^B r_C &= {}^E v_{EC} = {}^E v_{EB} + {}^E w_{EBx} {}^E R_B {}^B r_C \end{aligned} \right\} \Rightarrow$$

$${}^E a_{EC} = {}^E \dot{v}_{EB} + {}^E \dot{w}_{EBx} {}^E R_B {}^B r_C + \left({}^E w_{EBx} ({}^E v_{EB} + {}^E w_{EBx} {}^E R_B {}^B r_C) \right) \Rightarrow \quad (2.22)$$

$${}^E a_{EC} = {}^E \dot{v}_{EB} + {}^E \dot{w}_{EBx} {}^E R_B {}^B r_C + {}^E w_{EBx} {}^E v_{EB} + {}^E w_{EBx} ({}^E w_{EBx} {}^E R_B {}^B r_C)$$

Conociendo las fuerzas de empuje representadas en el marco fijo al cuerpo $\{B\}$, para relacionar los vectores de velocidad y aceleración lineal se toman las ecuaciones (2.21) y (2.22) y se obtiene las siguientes expresiones:

$${}^E v_{EC} = {}^E v_{EB} + {}^E w_{EBx} {}^B r_C \quad (2.23)$$

$${}^B a_{EC} = {}^B \dot{v}_{EB} + {}^B \dot{w}_{EB} x^B r_C + {}^B w_{EB} x^B v_{EB} + {}^B w_{EB} x^B ({}^B w_{EB} x^B r_C) \Rightarrow \quad (2.24)$$

Luego, la ecuación (2.17) puede escribirse como:

$${}^B f = m {}^B a_{EC} = m ({}^B \dot{v}_{EB} + {}^B \dot{w}_{EB} x^B r_C + {}^B w_{EB} x^B v_{EB} + {}^B w_{EB} x^B ({}^B w_{EB} x^B r_C)) \quad (2.25)$$

2.2.4 Ecuación de Euler

Esta ecuación relaciona el torque ejercido sobre un cuerpo con su velocidad lineal, su velocidad angular y la aceleración provocada.

$${}^B T_B = m {}^B r_C x^B ({}^B a_{EB}) + {}^B I_B {}^B \dot{w}_{EB} + {}^B \dot{w}_{EB} x^B I_B {}^B w_{EB} \quad (2.26)$$

$${}^B T_B = m {}^B r_C x^B ({}^B \dot{v}_{EB} + {}^B w_{EB} x^B v_{EB}) + {}^B I_B {}^B \dot{w}_{EB} + {}^B w_{EB} x^B I_B {}^B w_{EB} \quad (2.27)$$

Cuando $\{B\}$ coincide con $\{C\}$, la ecuación se simplifica así:

$${}^C T = {}^C I_C {}^C \dot{w}_{EC} + {}^C w_{EC} x^C I_C {}^C w_{EC} \quad (2.28)$$

2.2.5 Tensor de inercia.

Si ${}^E r_i = (x, y, z)^T$ es el vector posición de la partícula i , y $S({}^E r_i)$ es la matriz obtenida del vector de componentes de ${}^E r_i$, entonces ${}^E I_B$ es el tensor de inercia definido por:

$${}^E I_B = - \int_V S({}^E r_i) S({}^E r_i) \rho dv \quad (2.29)$$

Donde v es el volumen y ρ es la densidad. Expandiendo la ecuación (2.29), se tiene:

$$\int_V S({}^E r_i) S({}^E r_i) \rho dv = - \int_V \begin{pmatrix} 0 & -z & y \\ z & 0 & -x \\ -y & x & 0 \end{pmatrix} \begin{pmatrix} 0 & -z & y \\ z & 0 & -x \\ -y & x & 0 \end{pmatrix} \rho dv \quad (2.30)$$

$$\int_V S({}^E r_i) S({}^E r_i) \rho dv = - \int_V \begin{pmatrix} y^2+z^2 & -xy & -xz \\ -xy & x^2+z^2 & -yz \\ -xz & -yz & x^2+y^2 \end{pmatrix} \rho dv \quad (2.31)$$

O también se puede expresar como:

$$\int_V (r_i^T r_i I - r_i r_i^T) \rho dv = \int_V \left(\begin{pmatrix} x^2+y^2+z^2 & 0 & 0 \\ 0 & x^2+y^2+z^2 & 0 \\ 0 & 0 & x^2+y^2+z^2 \end{pmatrix} - \begin{pmatrix} x^2 & xy & xz \\ yx & y^2 & yz \\ zx & zy & z^2 \end{pmatrix} \right) \rho dv \quad (2.32)$$

$$- \int_V S({}^E r_i) S({}^E r_i) \rho dv = \int_V \begin{pmatrix} y^2+z^2 & -xy & -xz \\ -xy & x^2+z^2 & -yz \\ -xz & -yz & x^2+y^2 \end{pmatrix} \rho dv \quad (2.33)$$

Usando cualquiera de las dos expresiones, el tensor de inercia se calcula como:

$${}^E I_B = \begin{pmatrix} \int_V (y^2+z^2) \rho dv & - \int_V xy \rho dv & - \int_V xz \rho dv \\ - \int_V xy \rho dv & \int_V (x^2+z^2) \rho dv & - \int_V yz \rho dv \\ - \int_V xz \rho dv & - \int_V yz \rho dv & \int_V (x^2+y^2) \rho dv \end{pmatrix} = \begin{pmatrix} I_{xx} & -I_{xy} & -I_{xz} \\ -I_{xy} & I_{yy} & -I_{yz} \\ -I_{xz} & -I_{yz} & I_{zz} \end{pmatrix} \quad (2.34)$$

Los componentes de la diagonal del tensor de inercia son llamados los momentos de inercia $\{I_{xx}, I_{yy}, I_{zz}\}$ y representa la inercia mostrada por el cuerpo en rotación pura alrededor de los ejes $\{x, y, z\}$ respectivamente. Los otros componentes son llamados los productos de inercia.

En sistemas con un DOF, se habla de la masa con un cuerpo rígido. En el caso de movimiento rotacional alrededor de un solo eje, aparece el término de “Momento de Inercia”. Para un cuerpo rígido que es libre de moverse en las 3 dimensiones hay un número infinito de posibles ejes de rotación.

En el caso de la rotación sobre un eje arbitrario se necesita una manera de caracterizar la distribución de masa del cuerpo rígido, aquí aparece el término tensor de inercia, el cual se puede tomar como una generalización del momento escalar de la inercia de un objeto.

2.2.6 Ecuaciones dinámicas de movimiento.

De ecuaciones anteriores, el comportamiento dinámico de un cuerpo rígido se puede describir por medio de las siguientes expresiones:

$${}^B f = m ({}^B \dot{v}_{EB} + {}^B \dot{w}_{EBx} {}^B r_C + {}^B w_{EBx} {}^B v_{EB} + {}^B w_{EBx} ({}^B w_{EBx} {}^B r_C)) \quad (2.35)$$

$${}^B T_B = m {}^B r_{cX} ({}^B \dot{v}_{EB} + {}^B w_{EBX} {}^B v_{EB}) + {}^B I_B + {}^B w_{EBX} {}^B I_B {}^B w_{EB} \quad (2.36)$$

Si

$$\begin{aligned} {}^B f &= (X Y Z)^T \\ {}^B T_B &= (K M N)^T \\ {}^B a_{EB} &= (\dot{u} \dot{v} \dot{w})^T \\ {}^B \alpha_{EB} &= (\dot{p} \dot{q} \dot{r})^T \\ {}^B v_{EB} &= (u v w)^T \\ {}^B w_{EB} &= (p q r)^T \\ {}^B r_c &= (c_x c_y c_z)^T \end{aligned} \quad (2.37)$$

Expandiendo las ecuaciones (2.35) y (2.36), se obtiene:

$$\begin{pmatrix} X \\ Y \\ Z \end{pmatrix} = \begin{pmatrix} m(\dot{u}-vr+wq)-c_x(q^2+r^2)+c_y(pq+\dot{r})+c_z(pr+\dot{q}) \\ m(\dot{v}-wp+uq)-c_y(r^2+p^2)+c_z(qr+\dot{p})+c_x(qp+\dot{r}) \\ m(\dot{w}-uq+vp)-c_z(p^2+q^2)+c_x(rp-\dot{q})+c_y(rq+p) \end{pmatrix} \quad (2.38)$$

$$\begin{pmatrix} K \\ M \\ N \end{pmatrix} \begin{pmatrix} I_{xx}\dot{p}+(I_{zz}-I_{yy})qr-(\dot{r}+pq)I_{xz}+(r^2-q^2)I_{yz}+(pr-\dot{q})I_{xy}+m(c_y(\dot{w}-uq+vp)-c_z(\dot{v}-wp+ur)) \\ I_{yy}\dot{q}+(I_{xx}-I_{zz})rp-(\dot{p}+qr)I_{xy}+(p^2-r^2)I_{zx}+(qp-\dot{r})I_{yz}+m(c_x(\dot{u}-vr+wq)-c_x(\dot{w}-uq+vp)) \\ I_{zz}\dot{r}+(I_{yy}-I_{xx})pq-(\dot{q}+rp)I_{yz}+(q^2-p^2)I_{xy}+(rq-\dot{p})I_{zx}+m((c_x(\dot{v}-wp+ur)-c_y(\dot{u}-vr+wq))) \end{pmatrix} = \quad (2.39)$$

Las ecuaciones (2.38) y (2.39) se pueden escribir en una sola ecuación, así:

$$\begin{pmatrix} X \\ Y \\ Z \\ K \\ M \\ N \end{pmatrix} = \begin{pmatrix} m & 0 & 0 & 0 & -mc_z & -mc_y \\ 0 & m & 0 & -mc_z & 0 & mc_x \\ 0 & 0 & m & mc_y & -mc_x & 0 \\ 0 & -mc_z & mc_y & I_{xx} & -I_{xy} & -I_{xz} \\ mc_z & 0 & -mc_x & -I_{xy} & I_{yy} & -I_{yz} \\ -mc_y & mc_x & 0 & -I_{xz} & -I_{yz} & I_{zz} \end{pmatrix} \begin{pmatrix} \dot{u} \\ \dot{v} \\ \dot{w} \\ \dot{p} \\ \dot{q} \\ \dot{r} \end{pmatrix} + \begin{pmatrix} 0 & 0 & 0 & m(c_z r + c_y q) & -m(c_x q - w) & -m(v + c_x r) \\ 0 & 0 & 0 & -m(c_y p - w) & m(c_z r - c_y q) & -m(c_y r - u) \\ 0 & 0 & 0 & -m(c_x r + v) & m(c_y r - u) & -m(c_x p + c_y q) \\ -m(c_y q + c_z r) & m(c_y p + w) & m(c_z p - v) & 0 & I_{yz} q - I_{xz} p + I_{zz} r & I_{yz} r + I_{xx} p - I_{yy} q \\ m(c_x q - w) & -m(c_z r + c_x p) & m(c_z q - u) & I_{yz} q + I_{xz} p + I_{zz} r & 0 & -I_{xz} - I_{xy} q + I_{xx} p \\ m(c_x r - v) & m(c_y r - u) & -m(c_x p + c_y q) & -I_{yz} r - I_{xy} p + I_{yy} q & I_{xz} r + I_{xy} q + I_{xx} p & 0 \end{pmatrix} \begin{pmatrix} u \\ v \\ w \\ p \\ q \\ r \end{pmatrix} \quad (2.40)$$

Y las ecuaciones dinámicas de movimiento se pueden resumir en la siguiente expresión:

$${}^B T_B = {}^B M_{RB} {}^B v + {}^B C ({}^B \dot{v}) {}^B v \quad (2.41)$$

Donde:

$${}^B T_B = ({}^B F \quad {}^B T_B)^T \quad (2.42)$$

$${}^B v = ({}^B v_{EB} \quad {}^B w_{EB})^T \quad (2.43)$$

$${}^B \dot{v} = ({}^B a_{EB} \quad {}^B \alpha_{EB})^T \quad (2.44)$$

Notación compacta de la matriz mrb (matrix rigid body):

$${}^B M_{RB} = \begin{pmatrix} mI_{3 \times 3} & -mS({}^B r_c) \\ mS({}^B r_c) & {}^B I_B \end{pmatrix} \quad (2.45)$$

2.2.7 Cálculo de la matriz de coriolis y centrípeta, a partir de la matriz de masas

Sea ${}^B M_{RB} > 0$ una matriz de inercia de 6×6 definida como:

$${}^B M_{RB} = \begin{pmatrix} M_{11} & M_{12} \\ M_{21} & M_{22} \end{pmatrix} \quad (2.46)$$

Se puede calcular una parametrización diagonal simétrica de la matriz de coriolis centrípeta, a partir de esta matriz inercia (Fossen, 1994):

$${}^B C({}^B v) = \begin{pmatrix} 0_{3 \times 3} & -S(M_{11} {}^B v_{EB} + M_{12} {}^B w_{EB}) \\ -S(M_{11} {}^B v_{EB} + M_{12} {}^B w_{EB}) & -S(M_{21} {}^B v_{EB} + M_{22} {}^B w_{EB}) \end{pmatrix} \quad (2.47)$$

2.2.8 Fuerzas de gravedad y flotación

La fuerza de flotación es la fuerza que actúa en el llamado centro de flotación (${}^E r_B$), y coincide con el centro del volumen del cuerpo. Esta fuerza se expresa en el marco de la tierra como:

$${}^E f_B = \begin{pmatrix} 0 \\ 0 \\ -\rho g v \end{pmatrix} \quad (2.48)$$

Donde:

ρ Densidad del fluido

v Volumen del cuerpo

g Aceleración de la gravedad.

Si el centro de gravedad del cuerpo y el centro de flotación no coinciden, entonces existe un torque de flotación dado por:

$${}^E \tau_B = {}^E r_B \times {}^E f_B \quad (2.49)$$

Las ecuaciones (2.48) y (2.49) se pueden expresar en el marco fijo al cuerpo usando la siguiente expresión:

$${}^E f_B = \begin{pmatrix} c\psi c\theta & c\psi c\theta & -s\theta \\ -s\psi c\varphi + c\psi s\theta s\varphi & c\psi c\varphi + s\varphi s\theta s\psi & c\theta s\varphi \\ s\psi s\varphi + c\psi c\varphi s\theta & -c\psi s\varphi + s\theta s\psi c\varphi & c\theta s\varphi \end{pmatrix}_E \begin{pmatrix} 0 \\ 0 \\ -\rho g v \end{pmatrix} \Rightarrow \quad (2.50)$$

$${}^E f_B = \begin{pmatrix} s\theta B \\ -c\theta s\varphi B \\ -c\theta c\varphi B \end{pmatrix} \quad (2.51)$$

Donde $B = \rho g v$

$${}^E \tau_B = \begin{pmatrix} x_b \\ y_b \\ z_b \end{pmatrix}_x \begin{pmatrix} s\theta B \\ -c\theta s\varphi B \\ -c\theta c\varphi B \end{pmatrix} = \begin{pmatrix} -y_b c\theta c\varphi B + z_b c\theta s\varphi B \\ z_b s\theta B + x_b c\theta c\varphi B \\ -x_b c\theta s\varphi B - y_b s\theta B \end{pmatrix} \quad (2.52)$$

Entonces:

$${}^E F_B = \begin{pmatrix} s\theta B \\ -c\theta s\varphi B \\ -c\theta c\varphi B \\ -y_b c\theta c\varphi B + z_b c\theta s\varphi B \\ z_b s\theta B + x_b c\theta c\varphi B \\ -x_b c\theta s\varphi B - y_b s\theta B \end{pmatrix} \quad (2.53)$$

Por su parte, la fuerza de gravedad se puede expresar fácilmente en el marco de la tierra como sigue:

$${}^E f_G = \begin{pmatrix} 0 \\ 0 \\ w \end{pmatrix} \quad (2.54)$$

Donde $w = mg$. De la misma forma, el torque de gravedad se expresa como:

$${}^E \tau_G = r_{cX} {}^E f_G \quad (2.55)$$

Como en el caso anterior, ambos (fuerza y torque de gravedad) pueden expresarse en el marco del cuerpo a partir de las siguientes expresiones:

$${}^E f_G = \begin{pmatrix} -s\theta w \\ c\theta s\varphi w \\ c\theta c\varphi w \end{pmatrix} \quad (2.56)$$

$${}^E \tau_B = \begin{pmatrix} x_b \\ y_b \\ z_b \end{pmatrix}_x \begin{pmatrix} -s\theta w \\ c\theta s\varphi w \\ c\theta c\varphi w \end{pmatrix} = \begin{pmatrix} y_c c\theta c\varphi w - z_c c\theta s\varphi w \\ -z_c s\theta w - x_c c\theta c\varphi w \\ x_c c\theta s\varphi w + y_c s\theta w \end{pmatrix} \quad (2.57)$$

Entonces:

$${}^E F_G = \begin{pmatrix} -s\varphi w \\ c\theta s\varphi w \\ c\theta c\varphi w \\ y_c c\theta c\varphi w - z_c c\theta s\varphi w \\ -z_c s\theta w - x_c c\theta c\varphi w \\ x_c c\theta s\varphi w + y_c s\theta w \end{pmatrix} \quad (2.58)$$

Cuando el centro de flotación está ubicado en el origen, la ecuación (2.53) se puede simplificar así:

$${}^B F_B = \begin{pmatrix} s\theta B \\ -c\theta s\varphi B \\ -c\theta c\varphi B \\ 0 \\ 0 \\ 0 \end{pmatrix} \quad (2.59)$$

De la misma forma, cuando el centro de gravedad coincide con el origen de $\{B\}$, la ecuación (2.58) se simplifica como:

$${}^B F_G = \begin{pmatrix} -s\theta w \\ c\theta s\varphi w \\ c\theta c\varphi w \\ 0 \\ 0 \\ 0 \end{pmatrix} \quad (2.60)$$

Si el vehículo es neutralmente flotante, $w=B$. La expresión sería:

$${}^B F_B + {}^B F_G = \begin{pmatrix} s\theta B \\ -c\theta s\varphi B \\ -c\theta c\varphi B \\ -y_b c\theta c\varphi B + z_b c\theta s\varphi B \\ z_b s\theta B + x_b c\theta c\varphi B \\ -x_b c\theta s\varphi B - y_b s\theta B \end{pmatrix} + \begin{pmatrix} -s\varphi w \\ c\theta s\varphi w \\ c\theta c\varphi w \\ y_c c\theta c\varphi w - z_c c\theta s\varphi w \\ -z_c s\theta w - x_c c\theta c\varphi w \\ x_c c\theta s\varphi w + y_c s\theta w \end{pmatrix} \Rightarrow \quad (2.61)$$

$${}^B F_B + {}^B F_G = \begin{pmatrix} 0 \\ 0 \\ 0 \\ (y_c y_b) c\theta c\varphi B - (z_c z_b) c\theta s\varphi w \\ -(z_c z_b) s\theta w - (x_c x_b) c\theta c\varphi w \\ (x_c x_b) c\theta s\varphi w + (y_c y_b) s\theta w \end{pmatrix} \quad (2.62)$$

Y si el centro de flotación y el de gravedad son el mismo que el origen de $\{B\}$, la fuerza y el torque resultantes, debidos a la gravedad y flotación, son cero.

2.2.9 Fuerzas de masa añadida

Es importante considerar que cuando un vehículo subacuático se mueve a través de un fluido, existe cierta cantidad del fluido que se mueve con él. Las matrices de inercia y de coriolis relacionan las aceleraciones y velocidades angulares y lineales del vehículo, con la fuerza ejercida sobre él. En la misma forma, las matrices de masa-añadida y de coriolis-añadido, relacionan las aceleraciones y velocidades angulares y lineales con la fuerza hidrodinámica ejercida por esta cantidad de fluido que se mueve con el vehículo.

En la Figura 2.6, se observa que cuando un vehículo se mueve dentro de un fluido, se crea una distribución de presión dinámica a su alrededor. De la ecuación de Bernoulli se sabe que la presión sobre una superficie diferencial dS depende de la velocidad de la partícula de fluido localizada en dS y de la altura de la columna de agua sobre ella y esta presión que actúa sobre dS ejerce sobre el cuerpo una fuerza diferencial dF y un torque diferencial $d\tau$. La adición de estas fuerzas y torques diferenciales son los llamados fuerza-añadida y torque-añadido (Ridao et al., 2001).

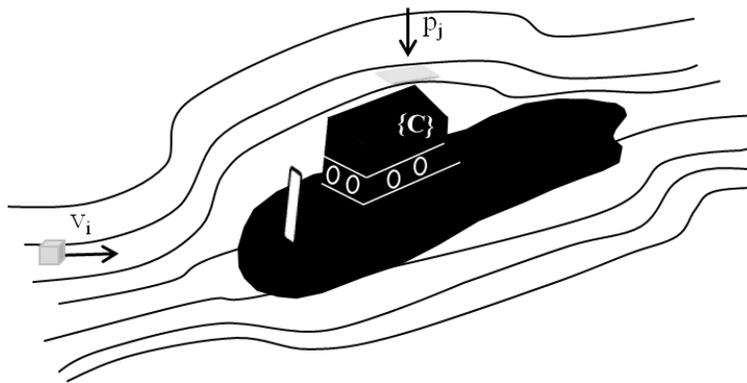


Figura 2.6. Flujo alrededor del vehículo subacuático.
Fuente: Tomada de (Ridao, 2001).

Suponiendo que se tiene un vehículo moviéndose a través de un fluido, la presión hidrostática es fácil de calcular, dependiendo únicamente de la altura de la columna de agua sobre la superficie del vehículo. Las dificultades emergen debido a la necesidad de calcular la distribución de velocidad del fluido en la superficie del cuerpo. Esto es necesario para calcular la presión hidrodinámica. Cuando se trabaja con fluidos ideales, este campo de velocidad se deriva de un campo potencial escalar φ .

Fluidos ideales

El movimiento de una partícula de fluido real se debe a un campo de fuerza externo, la fuerza gravitacional y los esfuerzos superficiales, o fuerzas por unidad de área, que actúan sobre superficies adyacentes del fluido. Esta última es ocasionada por la viscosidad del fluido. Debido a este efecto de la viscosidad, una partícula de fluido localizada en la superficie del

cuerpo se mueve con la misma velocidad que el cuerpo (condición de frontera). Una partícula localizada justo por encima de esta superficie tiene una velocidad diferente. En efecto, existe una distribución de velocidad ejercida sobre una superficie dS que va de la velocidad del cuerpo a la velocidad del fluido más lejano. El movimiento de este tipo de fluido se describe por la ecuación diferencial parcial de Navier-Stokes, la cual relaciona la velocidad de la partícula de fluido y su derivada parcial con la presión y fuerza hidrostáticas. Dado que es muy difícil trabajar con este tipo de ecuación, frecuentemente se acostumbra trabajar con fluidos ideales. Un fluido ideal es un fluido en el cual no hay efectos viscosos. En este caso, se considera que una partícula del cuerpo ubicada en dS no se mueve a la velocidad del cuerpo. Por el contrario, se considera en reposo con respecto a dS . Esta consideración puede ser calculada cuando la capa de frontera es permisible y suficientemente delgada. Se ha comprobado que si el campo de velocidad es irrotacional, se puede representar simplemente como el gradiente de una función escalar φ llamada potencial de velocidad (Ridao et al., 2001).

Fuerzas y momentos de masa añadida

De la Figura 2.7 se derivan las siguientes expresiones para calcular la fuerza y el torque de la masa añadida:

$${}^B F_A = \int_{S_B} \rho {}^B n dS \quad (2.63)$$

$${}^B T_A = \int_{S_B} \rho ({}^B r \times {}^B n) dS \quad (2.64)$$

Donde S_B es la superficie del cuerpo y ${}^B n$ es el vector normal a la superficie. En Newman (1997) se demuestra que estas fuerzas y momentos pueden expresarse de forma matricial:

$$\begin{pmatrix} {}^B F \\ {}^B T \end{pmatrix} = \begin{pmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{pmatrix} \begin{pmatrix} {}^B \dot{v}_{EB} \\ {}^B \dot{w}_{EB} \end{pmatrix} + \begin{pmatrix} 0_{3 \times 3} & -S(A_{11} {}^B v_{EB} + A_{12} {}^B w_{EB}) \\ -S(A_{11} {}^B v_{EB} + A_{12} {}^B w_{EB}) & -S(A_{21} {}^B v_{EB} + A_{22} {}^B w_{EB}) \end{pmatrix} \begin{pmatrix} {}^B v_{EB} \\ {}^B w_{EB} \end{pmatrix} \quad (2.65)$$

Otra forma más simplificada es:

$$\begin{pmatrix} {}^B F \\ {}^B T \end{pmatrix} {}^B F_A = M_A {}^B \dot{v} + C_A ({}^B v) {}^B v \quad (2.66)$$

Donde $C_A ({}^B v, M_A)$ es la matriz de coriolis añadida

$${}^B v = ({}^B v_{EB} \quad {}^B w_{EB})^T = (v_1, v_2, v_3, v_4, v_5, v_6) \quad (2.67)$$

${}^B v_{EB}$ = velocidad lineal

${}^B w_{EB}$ = velocidad angular

M_A = matriz de masa añadida y está dada por:

$$M_A = \begin{pmatrix} a_{11} & \dots & a_{16} \\ \vdots & \ddots & \vdots \\ a_{61} & \dots & a_{66} \end{pmatrix} = \begin{matrix} a_{11} & a_{12} \\ a_{11} & a_{22} \end{matrix} \quad (2.68)$$

En la Figura 2.7 se aprecia la representación de la fuerza y el torque ejercidos sobre el cuerpo

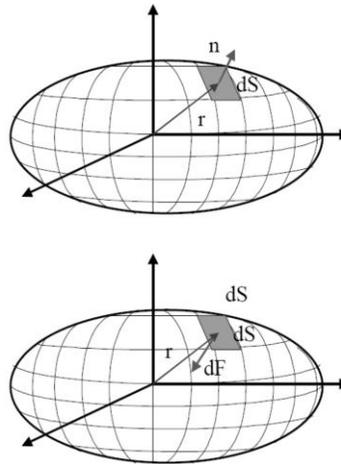


Figura 2.7. Fuerza y torque ejercidos sobre el cuerpo.
Fuente: Tomada de (Ridao et al., 2001).

La matriz de masa añadida es una colección de tensores de masa añadidos a_{ij} , característicos de un vehículo:

$$a_{ij} \equiv -\rho \int_{S_B} \varphi_i \frac{\partial \varphi_j}{\partial t^B} n \, dS \quad (2.69)$$

Propiedades del tensor de masa añadida

El tensor de masa añadida tiene las siguientes propiedades:

- Los coeficientes del tensor de masa añadida son simétricos ($a_{ij} = a_{ji}$), por lo tanto existen veintiún coeficientes independientes. Este número puede reducirse drásticamente si el cuerpo es simétrico respecto a uno o más ejes. (Newman, 1997).
- En ausencia de simetría, los coeficientes de acoplamiento cruzado del tensor de masa añadida (a_{12}, a_{13} , y a_{23}) son diferentes de cero, lo que implica que la dirección de la fuerza hidrodinámica es diferente a la dirección de la aceleración.
- Los coeficientes del tensor de masa añadida dependen únicamente de la forma del cuerpo.

- Existe una relación simple entre el tensor de masa añadida y la energía cinética del fluido:

$$T = \frac{1}{2} B_v M_A B_v \quad (2.70)$$

2.2.10 Amortiguamiento hidrodinámico

Existen dos conjuntos de fuerzas de amortiguamiento hidrodinámico que deben tenerse en cuenta cuando se trabaja con vehículos subacuáticos (Fossen, 1994) . Uno es el arrastre y empuje cuadráticos, y el otro es la fricción lineal de piel. Aunque, en general, el amortiguamiento de un vehículo subacuático con 6 grados de libertad y a alta velocidad sería altamente no lineal y acoplado, muchos autores proponen una serie de simplificaciones para hacer análisis de los modelos. La simplificación más común es considerar que la fuerza de amortiguamiento lineal cuadrática en el eje i depende únicamente de la componente i del vector de velocidad. Esto es casi lo mismo que considerar que el vehículo realiza movimientos desacoplados y tiene tres planos casi simétricos. Trabajando bajo esta consideración, la fuerza de amortiguamiento se puede expresar como:

$$F_D = - \begin{pmatrix} X_u u \\ Y_v v \\ Z_w w \\ K_p p \\ M_q q \\ N_r r \end{pmatrix} - \begin{pmatrix} X_{u|u}|u|u \\ Y_{v|v}|v|v \\ z_{w|w}|w|w \\ K_{p|p}|w|w \\ M_{q|q}|q|q \\ N_{r|r}|r|r \end{pmatrix} \quad (2.71)$$

Donde x_u y $X_{u|u}$ son los coeficientes de viscosidad lineal y cuadrático respectivamente en la dirección de X . Muchos autores consideran que la fuerza de empuje es insignificante comparada con la de arrastre (Contre & Serrani, 1996), esto se expresa como:

$$X_{u|u}|u|u = \frac{1}{2} \rho C_{D_x} A_x |u|u \quad (2.72)$$

Donde:

ρ = densidad del fluido

C_{D_x} = coeficiente de arrastre en la dirección de X

A_x = área de la sección del cuerpo en la dirección de X

De esta forma, la ecuación (2.71) puede reescribirse así:

$$F_D = - \begin{pmatrix} X_u u \\ Y_v v \\ Z_w w \\ K_p p \\ M_q q \\ N_r r \end{pmatrix} - \begin{pmatrix} \frac{1}{2} \rho C_{D_x} A_x |u| u \\ \frac{1}{2} \rho C_{D_y} A_y |v| v \\ \frac{1}{2} \rho C_{D_z} A_z |w| w \\ \frac{1}{2} \rho C_{D_p} |p| p \\ \frac{1}{2} \rho C_{D_q} |q| q \\ \frac{1}{2} \rho C_{D_r} |r| r \end{pmatrix} \quad (2.73)$$

O en notación matricial:

$$F_D = \begin{pmatrix} X_u + X_{u|u}|u| & 0 & 0 & 0 & 0 & 0 \\ 0 & Y_v + Y_{v|v}|v| & 0 & 0 & 0 & 0 \\ 0 & 0 & Z_w + Z_{w|w}|w| & 0 & 0 & 0 \\ 1 & 0 & 0 & K_p + K_{p|p}|p| & 0 & 0 \\ 0 & 1 & 0 & 0 & M_u + M_{q|q}|q| & 0 \\ 0 & 0 & 0 & 0 & 1 & N_u + N_{r|r}|r| \end{pmatrix} \begin{pmatrix} u \\ v \\ w \\ p \\ q \\ r \end{pmatrix} \quad (2.74)$$

2.2.11 Fuerzas ambientales

Algunas fuerzas ambientales deben considerarse en vehículos subacuáticos cuando estos van a ser sumergidos en el océano, estas son:

- Olas superficiales
- Viento
- Corrientes oceánicas

Para los vehículos que se sumergen a una profundidad mayor a 20 metros, el efecto de las olas puede ser ignorado. El viento sólo tiene efecto cuando el vehículo se mueve en la superficie. Por lo tanto, las únicas perturbaciones que deben considerarse en vehículos que se sumergen en el océano, son las corrientes oceánicas.

2.3 Modelo general del sistema

Al describir la cinemática y la dinámica que afectan a un vehículo subacuático, se pueden resumir las expresiones necesarias para el modelo. De acuerdo con las expresiones matemáticas referidas en el capítulo 2, relacionadas con la dinámica de un vehículo submarino, la ecuación general que describe dicha dinámica puede expresarse como sigue:

$${}^B T_B + G(O) - D({}^B v) {}^B v + P_E = ({}^G M_{RB} + M_A) {}^G \dot{v} + ({}^B C_{RB}({}^B v) + C_A({}^B v)({}^B v)) \quad (2.75)$$

Donde:

${}^B\dot{v} = ({}^B a_{EB}, {}^B \alpha_{EB})^T =$	Vector de aceleración
${}^B v = ({}^B v_{EB}, {}^B w_{EB})^T =$	Vector de velocidad
$O = (\varphi \ \theta \ \psi)^T =$	Ángulos de Euler
${}^B T_B =$	Fuerzas y momentos ejercidas por los propulsores
$G(O) =$	Fuerzas de flotación y gravedad
$D({}^B v) =$	Matriz de amortiguamiento
$P_E =$	Perturbaciones no modeladas (corrientes, etc.)
${}^B M_{RB} =$	Matriz de inercia
${}^B M_A =$	Matriz de masa añadida
${}^B C_{RB} =$	Matriz de coriolis del cuerpo rígido
${}^B C_A =$	Matriz de coriolis de masa añadida.

2.3.1 Fuerzas y torques de los propulsores

Las fuerzas y torques ejercidas por los propulsores en el vehículo se definen como:

$${}^B T_B = B u \quad (2.76)$$

$$u_i = |w_i| w_i \quad (2.77)$$

$$B_{6 \times n} = \begin{pmatrix} \sum_{i=1}^n C_{Ti} \\ \sum_{i=1}^n ({}^B C_{Ti} + {}^B r_i \times C_{Ti}) \end{pmatrix} \quad (2.78)$$

$$\dot{w}_i = \beta_i \tau_i - \alpha_i u_i \quad (2.79)$$

$$T_i = C_{Ti} |w_i| w_i \quad (2.80)$$

$$\tau_i = C_{\tau i} |w_i| w_i \quad (2.81)$$

Donde:

${}^B T_B =$	Vector de fuerzas y torques, de dimensión 6×1
$B =$	Matriz de configuración del propulsor, de dimensión $6 \times n$
$u =$	Cuadrados de las velocidades del propulsor
$n =$	Número de propulsores
$w_i =$	Velocidad del propulsor i
$C_{Ti} =$	Vector de 3×1 con los parámetros de fuerza C_T en (x, y, z) para el propulsor i
$C_{\tau i} =$	Vector de 3×1 con los parámetros del torque C_τ en (x, y, z) para el propulsor i

- ${}^B r_i =$ Vector de 3×1 que contiene la posición del propulsor i
 $\beta_i, \alpha_i =$ Parámetros de la dinámica del propulsor
 $T_i =$ Vector de 3×1 que contiene las fuerzas del propulsor i
 $\tau_i =$ Vector de 3×1 que contiene los torques del propulsor i

2.3.2 Fuerzas y torques de gravedad y flotación

Si el peso, volumen y forma del vehículo no cambian, las fuerzas de gravedad y flotación son fuerzas constantes en el sistema de coordenadas fijo a tierra. En estos casos, las fuerzas solo tienen que ser referenciadas en el sistema coordenado del vehículo, dependiendo de su orientación. Si el peso, el volumen o la forma del vehículo cambian, las fuerzas y momentos también lo harán. Sin embargo, si se considera que el sistema coordenado del vehículo tiene su origen en su centro de gravedad, las ecuaciones generales para estas fuerzas y momentos, son:

$$G(O) = {}^B F_B + {}^B F_G \quad (2.82)$$

$${}^B F_B = \begin{pmatrix} s\theta B \\ -c\theta s\varphi B \\ -c\theta c\varphi B \\ -y_b c\theta c\varphi B + z_b c\theta s\varphi B \\ z_b s\theta B + z_b c\theta s\varphi B \\ -x_b c\theta s\varphi B - y_b s\theta B \end{pmatrix} \quad (2.83)$$

$${}^B F_G = \begin{pmatrix} -s\theta w \\ c\theta s\varphi w \\ c\theta c\varphi w \\ 0 \\ 0 \\ 0 \end{pmatrix} \quad (2.84)$$

Donde:

- $G(O) =$ Fuerzas y momentos de gravedad y flotación
 $G = (\varphi \theta \psi)^T =$ Ángulos de Euler
 ${}^B F_B =$ Fuerzas y torques de flotación
 ${}^B F_G =$ Fuerzas y torques de gravedad
 $B =$ Magnitud de la fuerza total de flotación
 $(x_b, y_b, z_b) =$ Centro de flotación
 $W =$ Magnitud de la fuerza total de gravedad

2.3.3 Fuerzas y torques de amortiguamiento

Las fuerzas de amortiguamiento dependen de la velocidad del vehículo. Las dos componentes principales son el amortiguamiento lineal y cuadrático. Las ecuaciones que resumen estas fuerzas son:

$$D({}^B v) {}^B v = D_L {}^B v + D_Q \text{diag}(|{}^B v|) {}^B v \quad (2.85)$$

$$D_L = \text{diag}(X_u \ Y_v \ Z_w \ K_p \ M_q \ N_r) \quad (2.86)$$

$$D_Q = \text{diag}(X_{u|u|} \ Y_{v|v|} \ Z_{w|w|} \ K_{p|p|} \ M_{q|q|} \ N_{r|r|}) \quad (2.87)$$

Donde:

$D({}^B v) {}^B v =$ Vector de fuerzas y torques de amortiguamiento

${}^B v = ({}^B v_{EB}, {}^B w_{EB})^T =$ Vector de velocidad

$D_L =$ Matriz de amortiguamiento lineal

$D_Q =$ Matriz de amortiguamiento cuadrático

$X_u, Y_v, Z_w, K_p, M_q, N_r =$ parámetros de amortiguamiento lineal

$X_{u|u|}, Y_{v|v|}, Z_{w|w|}, K_{p|p|}, M_{q|q|}, N_{r|r|} =$ parámetros de amortiguamiento cuadrático

2.3.4 Ecuación dinámica de movimiento

La dinámica del vehículo está determinada por la cantidad total de fuerza y torque. Con el marco de referencia del vehículo ubicado en el centro de gravedad, las expresiones de la matriz de inercia, matriz de masa añadida y sus correspondientes matrices de coriolis, son:

$$\sum \begin{bmatrix} F_i \\ T_i \end{bmatrix} = ({}^B M_{RB} + {}^B M_A) {}^B \dot{v} + ({}^B C_{RB}({}^B v) + {}^B C_A({}^B v)) {}^B v \quad (2.88)$$

$${}^B M_{RB} = {}^B \begin{pmatrix} M_{11} & M_{12} \\ M_{21} & M_{22} \end{pmatrix} = \begin{pmatrix} m_{3 \times 3} & 0 \\ 0 & {}^B I_B \end{pmatrix} = z \begin{pmatrix} m & 0 & 0 & 0 & 0 & 0 \\ 0 & m & 0 & 0 & 0 & 0 \\ 0 & 0 & m & 0 & 0 & 0 \\ 0 & 0 & 0 & I_{xx} & -I_{xy} & -I_{xz} \\ 0 & 0 & 0 & -I_{xy} & I_{yy} & I_{yz} - I_{yz} \\ 0 & 0 & 0 & -I_{xz} & -I_{yz} & I_{zz} \end{pmatrix} \quad (2.89)$$

$$M_A = \begin{pmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{pmatrix} = \begin{pmatrix} a_{11} & \dots & a_{16} \\ \vdots & \ddots & \vdots \\ a_{61} & \dots & a_{66} \end{pmatrix} \quad (2.90)$$

$${}^B C_{RB}({}^c v) = \begin{pmatrix} 0_{3 \times 3} & -S(M_{11} {}^B v_{EB} + M_{12} {}^G w_{EB}) \\ -S(M_{11} {}^B v_{EB} + M_{12} {}^B w_{EB}) & -S(M_{21} {}^B v_{EB} + M_{22} {}^B w_{EB}) \end{pmatrix} \quad (2.91)$$

$$C_A({}^c v) = \begin{pmatrix} 0_{3 \times 3} & -S(A_{11} {}^B v_{EB} + A_{12} {}^B w_{EB}) \\ -S(A_{11} {}^B v_{EB} + A_{12} {}^B w_{EB}) & -S(A_{21} {}^B v_{EB} + A_{22} {}^B w_{EB}) \end{pmatrix} \quad (2.92)$$

$$S([a \ b \ c]) = \begin{bmatrix} 0 & -c & b \\ c & 0 & -a \\ -b & a & 0 \end{bmatrix} \quad (2.93)$$

Donde:

$F_i =$ Fuerzas aplicadas al vehículo

$T_i =$ Torques aplicados al vehículo

${}^B v = ({}^B v_{EB}, {}^B w_{EB})^T =$ Vector de velocidad

${}^B M_{RB} =$	Matriz de inercia del cuerpo rígido
${}^B M_A =$	Matriz de masa añadida
${}^B C_{RB} =$	Matriz de coriolis del cuerpo rígido
${}^B C_A =$	Matriz de coriolis de la masa añadida
$m =$	Masa del vehículo
$I_B =$	Matriz de momento de inercia
$a_{ij} =$	Parámetro de la masa añadida

2.3.5 Ecuación final del modelo

Una vez que la ecuación dinámica (2.75) está completamente definida, pueden calcularse la aceleración, velocidad y posición. Para propósitos de simulación es importante calcular la evolución de la posición y orientación del vehículo en función de las fuerzas que actúan sobre él. Esto puede hacerse reorganizando los términos de la ecuación (2.75):

$${}^B \dot{v} = ({}^B M_{RB} + M_A)^{-1} \left({}^B T_B + G(O) - D({}^B v) {}^B v + \tau_E - ({}^B C_{RB}({}^B v) + C_A({}^B v)) ({}^B v) \right) \quad (2.94)$$

El acoplamiento entre las variables de la ecuación 2.94 se presenta en los términos ${}^B M_{RB}$ que corresponde a la matriz de inercia de cuerpo rígido y en ${}^B C_{RB}$ que corresponde a la matriz de coriolis del cuerpo rígido. El vector de velocidad se calcula mediante un operador de integración:

$${}^B v = \int {}^B \dot{v} dt \quad (2.95)$$

La velocidad con referencia a la tierra se obtiene usando la expresión (2.74), y finalmente la posición y orientación del vehículo en el marco de la tierra se obtiene integrando la velocidad:

$$\begin{pmatrix} x \\ y \\ z \\ \varphi \\ \theta \\ \psi \end{pmatrix} = \int {}^B v dt \quad (2.96)$$

En la Figura 2.8 se muestra la implementación del modelo del ROV en el software de Simulink de Matlab 2010. Las especificaciones para hacer la simulación, se presentan en el Apéndice A.

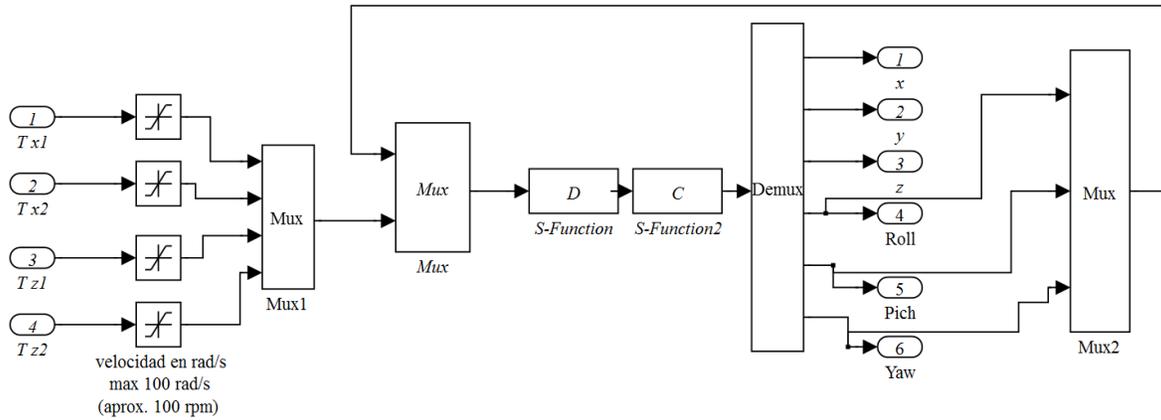


Figura 2.8. Implementación del modelo de un ROV en MATLAB-Simulink.
Fuente: Autores del proyecto, 2012.

De la Figura 2.10 a la Figura 2.15 se presenta la respuesta en lazo abierto del modelo del ROV, mostrado en la Figura 2.8, en términos de las variables de salida, para una entrada sinusoidal no sincrónica (ver Figura 2.9) a los actuadores T_{x1} , T_{x2} , T_{z1} y T_{z2} . El bloque D representa la matriz de valores de amortiguamiento del sistema y el bloque C representa los valores derivados de la matriz de coriolis de la dinámica del sistema.

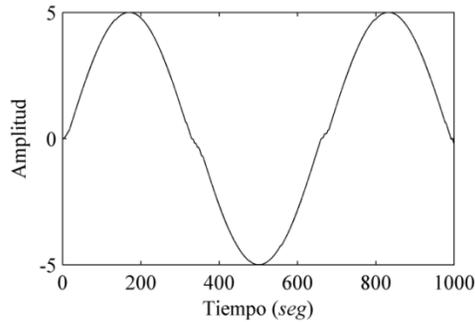


Figura 2.9. Señal de entrada no sincrónica a cada uno de los actuadores.
Fuente: Autores del proyecto, 2012.

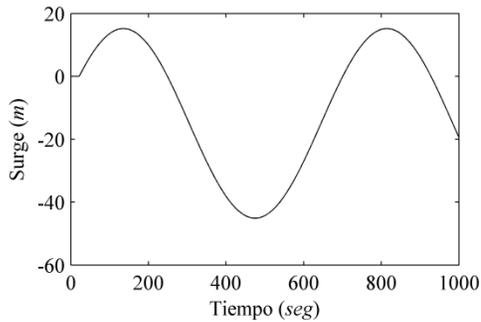


Figura 2.10. Respuesta de lazo abierto en x (surge).
Fuente: Autores del proyecto, 2012.

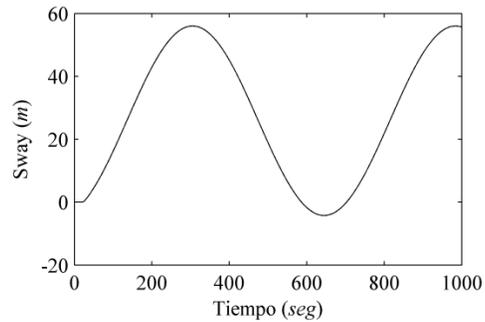


Figura 2.11. Respuesta de lazo abierto en y (sway).
Fuente: Autores del proyecto, 2012.

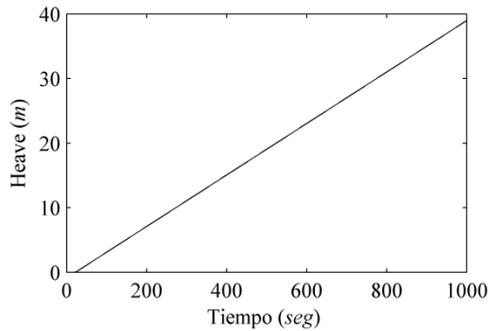


Figura 2.12. Respuesta de lazo abierto en z (*heave*).
Fuente: Autores del proyecto, 2012.

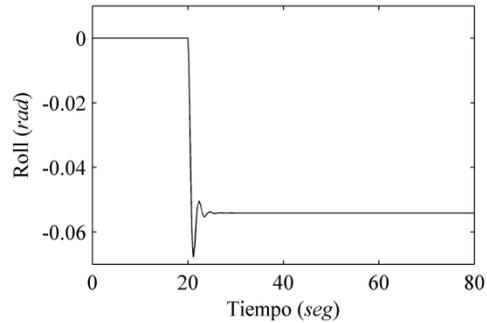


Figura 2.13. Respuesta de lazo abierto en ϕ (*roll*).
Fuente: Autores del proyecto, 2012.

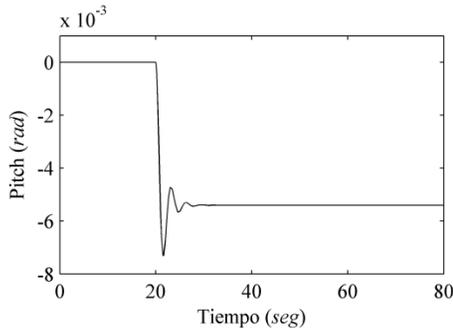


Figura 2.14. Respuesta de lazo abierto en θ (*pitch*).
Fuente: Autores del proyecto, 2012.

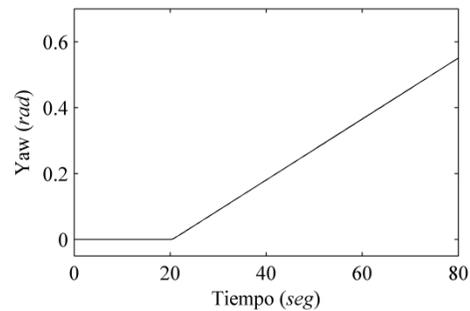


Figura 2.15. Respuesta de lazo abierto en ψ (*yaw*).
Fuente: Autores del proyecto, 2012.

Se puede observar en las Figuras 2.13 y 2.14 que la respuesta en lazo abierto de las salidas angulares del ROV correspondientes al *roll* y al *pitch* son estables, tal y como lo han reportado estudios anteriores en la literatura para este tipo de sistemas (Javadi-Moghaddam & Bagheri, 2010). Por lo tanto, el sistema de control debe concentrar su mayor esfuerzo en lograr que las otras cuatro variables de salida sigan las referencias pre-establecidas. Así también, se pueden observar en las Figuras 2.12 y 2.15, las respuestas para las variables de salida *heave* y *yaw*, las cuales reflejan mayor inestabilidad en la operación del sistema.

2.4 Procedimiento propuesto

Considerando los reportes del estado del arte, un Sistema de Inferencia Difuso Neuronal Adaptativo (ANFIS) posee un sistema de inferencia que provee un mecanismo intuitivo y de alto nivel para representar el conocimiento mediante relaciones difusas, lo que permite la implementación de modelos capaces de manejar las incertidumbres. Para que este tipo de sistemas garantice el tratamiento de la incertidumbre sin afectar el desempeño de las estructuras de control y la consistencia en la precisión, deben estar compuestos por modelos híbridos soportados en rutinas de optimización y análisis probabilístico. En la literatura se puede apreciar que la mayor bondad de estas redes es su capacidad de auto ajuste, gracias a sus elementos procesales y su sistema dinámico que le permite cambiar y adoptar nuevos

comportamientos frente a diferentes condiciones, aún dadas por el azar. También se reporta que los modelos neuro-difusos más usados y mejor conocidos para el control estocástico se basan en el modelo ANFIS y se aprecia la ventaja frente al control convencional de evitar modelos matemáticos complejos, además de alcanzar altos niveles de precisión, dimensionalidad y simplicidad. De acuerdo con esto y al momento de considerar un sistema estocástico con información incompleta, para el caso del ROV, donde el ambiente puede inducir perturbaciones al sistema, es pertinente que el control esté compuesto por modelos híbridos que permitan combinar las ventajas neuro-difusas con métodos probabilísticos y evolutivos, y así conformar estructuras de control adaptativas que traten adecuadamente las incertidumbres sin afectar la precisión y la consistencia en los resultados.

Uno de los principales problemas que presenta el monitoreo y control de un vehículo operado remotamente para aplicaciones submarinas, está centrado principalmente en el control de sistemas acoplados, en los cuales las variables que describen la dinámica del sistema están interrelacionadas, esto sin contar la disponibilidad de las observaciones de cada una de ellas y los cambios inesperados del comportamiento. Es por esto que en el procedimiento propuesto de esta tesis, se desarrolla y analiza un modelo neuro-difuso, para la identificación y control de sistemas dinámicos acoplados estocásticos con observaciones incompletas. Para la identificación del sistema, se procederá con la obtención de un modelo en términos de un modelo autorregresivo neuronal, teniendo en cuenta los diagramas de autocorrelación y autocorrelación parcial para determinar el grado del sistema, mientras que las perturbaciones del sistema serán modeladas mediante la utilización de un proceso con reversión a la media del tipo Ornstein-Uhlenbeck, a fin de establecer una representación teórica de las perturbaciones, y así, lograr la estabilidad general del modelo a pesar del comportamiento estocástico de las perturbaciones. Para el diseño del controlador, se apelará a la estructura de las redes neuronales de tipo MADALINE, así como modelos difusos por adaptación y aprendizaje del tipo ANFIS, teniendo en cuenta para ello el comportamiento del error del sistema frente a la referencia. El esquema que se sigue en el procedimiento de esta tesis se presenta en la Figura 2.16.

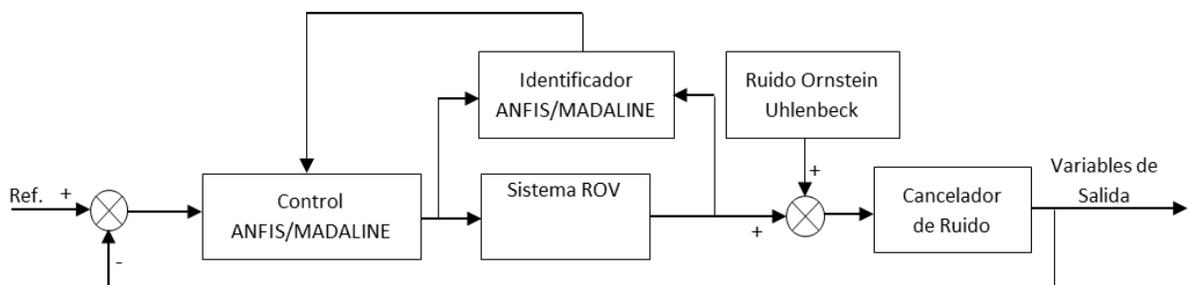


Figura 2.16. Diagrama de la metodología propuesta.
Fuente: Autores del proyecto, 2012.

2.4.1 Sistemas acoplados con información incompleta

La representación de un sistemas dinámico en espacio de estados, es un modelo matemático que permite la representación de un sistema físico en términos de sus entradas, salidas y sus variables de estado, las cuales están relacionadas por medio de ecuaciones diferenciales de primer orden. De forma general, la representación de un sistema en espacio de estados de un sistema lineal con (NC) entradas, (NS) Salidas y (NE) variables de estado discreto y variante en el tiempo, se puede escribir de la siguiente manera (Ogata, 1996):

$$\dot{x}(k)=A(k)x(k)+B(k)u(k) \quad (2.97)$$

$$y(k)=C(k)x(k)+D(k)u(k) \quad (2.98)$$

Donde:

- $x(k)$: Representa el vector de estados del sistema.
- $y(k)$. Representa el vector de salida del sistema.
- $u(k)$: Representa el vector de entradas del sistema.
- $A(k)$. Representa la matriz de estados del sistema.
- $B(k)$: Representa la matriz de entrada.
- $C(k)$: Representa la matriz de salida.
- $D(k)$: Representa la matriz de transición directa.

Así, $x(k) \in R^{NE}$, $y(k) \in R^{NS}$, $u(k) \in R^{NC}$, y de esta manera, la representación de un sistema en espacio de estados para un sistema lineal variante en el tiempo de tipo estocástico y con perturbaciones a la entrada, se puede expresar de la siguiente manera (Ogata, 1996):

$$\dot{x}(k)=A(k)x(k)+B(k)u(k)+G(k)e(k) \quad (2.99)$$

$$y(k)=C(k)x(k)+D(k)u(k) \quad (2.100)$$

Donde:

- $G(k)$: Representa la matriz de entrada de perturbación del comportamiento del sistema.
- $e(k)$: Representa el vector de perturbación, el cual puede ser representado en términos de un proceso estocástico.

Las perturbaciones que afectan un sistema, se pueden expresar en términos de tres procesos estocásticos como:

1. Procesos de Ornstein-Uhlenbeck con reversión a la media.
2. Movimientos Brownianos Geométricos.
3. Movimientos Brownianos Aritméticos.

Estos procesos estocásticos cuando se hacen observables en un espacio de estados configuran sistemas dinámicos de tipo estocástico, ya que la observabilidad de un sistema indica la posibilidad de que los estados internos puedan ser inferidos conociendo las salidas externas.

Por lo tanto, un modelo de espacio de estados discreto e invariante en el tiempo es *Observable*, si y sólo si (Ogata, 2010):

$$\text{rank} \begin{bmatrix} C \\ CA \\ \dots \\ CA^{n-1} \end{bmatrix} = n \quad (2.101)$$

Debido a que la expresión (2.101) no contiene la matriz de perturbación $G(k)$, se genera un sistema dinámico con observaciones incompletas, sin contar con que el comportamiento del vector de perturbación $e(k)$ también puede ser descrito en términos de un proceso estocástico usando las expresiones anteriormente descritas (Raffo & Mejía, 2006).

2.4.2 Estructura del modelo de identificación

Para la identificación de un sistema dinámico de tipo estocástico con observaciones incompletas, se procede inicialmente con la obtención de los diagramas de autocorrelación (DAC) y autocorrelación parcial (DACP) por cada una de las señales de respuesta del sistema (i.e., 6 señales). Estos diagramas permitieron determinar la estructura del modelo de identificación, así como el grado del mismo.

Para el caso de sistemas acoplados, una señal de salida estará expresada en términos de cada uno de los retardos asociados con las demás señales de salida y sus propios retardos, por lo que los DAC y DACP pueden estimarse de manera independiente por señal, mientras que el modelo propuesto para la identificación, se encarga de determinar la dinámica del sistema y la interrelación interna entre las variables. Los DAC y DACP obtenidos para una de las variables de las cuales se compone el sistema, se muestran en la Figura 2.17.

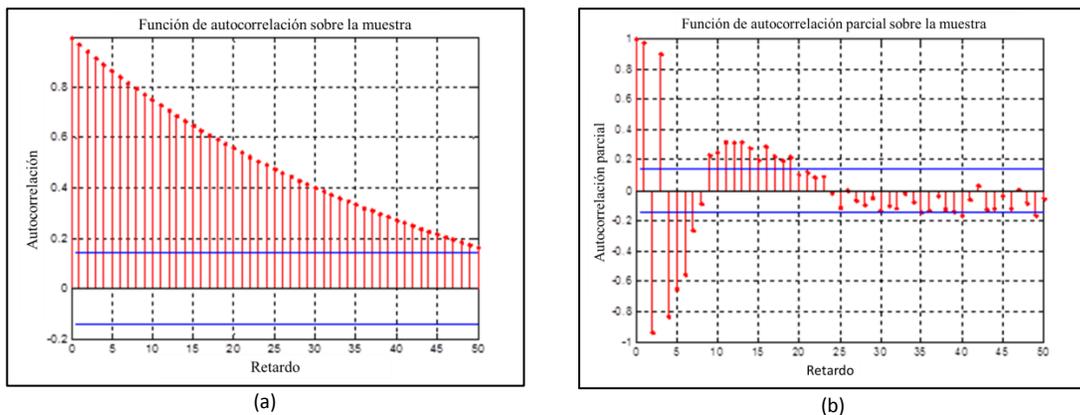


Figura 2.17. Diagramas de (a) Autocorrelación (b) Autocorrelación Parcial.

Fuente: Autores del proyecto, 2012.

De acuerdo con la Figura 2.17 (a), se puede observar que la señal de salida para la variable x , muestra que la identificación requiere de un modelo de tipo autorregresivo, mientras que la Figura 2.17 (b) muestra el número de retardos que permitirían describir una variable de salida. De esta manera, y de acuerdo con los objetivos propuestos en este proyecto de investigación,

los modelos más adecuados para la identificación y control de sistemas acoplados de tipo estocástico, están basados estructuralmente en términos de modelos por adaptación y aprendizaje tales como (Da Silva, 2006):

- Modelos neuronales del tipo MADALINE (Sánchez & Alanis G., 2006).
- Modelos neuro-difusos del tipo ANFIS (Zúñiga & Jordán, 2005).

A. Modelo Neuronal MADALINE

Al tomar en consideración los diagramas DACP y DAC mostrados en la Figura 2.16, la estructura del modelo de identificación basado en la estructura de una red neuronal tipo MADALINE, toma la siguiente forma (Sánchez & Alanis G., 2006):

$$y r_m = C_{j,m}(w_{j,i} x_i) \quad (2.102)$$

Donde:

x_i : Representa el vector de entrada al modelo de identificación.

Sin perder generalidad, y de acuerdo con los DAC y DACP exhibidos por el posicionamiento del ROV (Chin, Lau, Low, & Seet, 2006) en la coordenada x en el espacio, este vector toma la siguiente forma:

$$x = [u_{1,k} \ u_{2,k} \ \dots \ u_{6,k} \ x_{1,k-2} \ x_{1,k-1} \ \dots \ x_{6,k-2} \ x_{6,k-1}] \quad (2.103)$$

Donde:

$u_{m,k}$: Representa la señal de entrada m para el sistema en el instante k .

$x_{m,k-na}$: Indica la variable dinámica m en el instante k , y na permite identificar el número de retardos considerados para dicha variable.

De acuerdo con la Figura 2.17, y sin perder generalidad, en el vector (2.103) se puede observar que los retardos considerados por el modelo autorregresivo de identificación para cada una de las m variables dinámicas fueron fijados en dos. Así, para sistemas que no son adaptativos, el número resulta importante para la identificación del sistema por parte de una red neuronal, pero para el caso de sistemas adaptativos de control, este número de retardos hace que el procesamiento computacional sea más alto en la actualización de los parámetros del modelo, sin afectar en mayor medida la respuesta del sistema.

Para el análisis de los resultados arrojados por el modelo de identificación para cada una de las variables que conforman la dinámica del ROV (Chin, Lau, Low, & Seet, 2006), se utiliza la metodología propuesta en (Park & Seok, 2007), donde se evalúa el desempeño en términos de los datos usando 8 métricas estadísticas, que de acuerdo con sus nombres en inglés se listan a continuación:

1. *Sesgo Fraccional* (FB, *Fractional Bias*)

2. *Error Cuadrático Medio Normalizado* (NMSE, *Normalized Mean Square Error*)
3. *Media Geométrica del Sesgo* (MG, *Geometric Mean*)
4. *Varianza Geométrica del Sesgo* (VG, *Geometric Variant*)
5. *Índice de Ajuste* (IOA, *Index of Agreement*)
6. *Exactitud no apareada de concentración máxima* (UAPC2, *Unpaired Accuracy of Peak*)
7. *Factor de medición dentro de un factor de observaciones* (FAC2, *Within a Factor of Two*)
8. *Media del error relativo* (MRE, *Mean Relative Error*)

Estas métricas están integradas en un solo modelo, donde cada una de ellas es descrita en términos de valores cualitativos, tales como, Excelente (*G*), Sobresaliente (*OF*), *Acceptable* (*F*), *Regular* (*UF*) y *Pobre* (*P*). Es importante resaltar que la forma en que se asigna cada una de estas cualidades a una métrica en particular es de la siguiente manera: cada métrica se normaliza entre 0 y 1 de forma que entre 0 y 0.3 es *P*; entre 0.3 y 0.5 es *UF*; entre 0.5 y 0.65 es *F*; entre 0.66 y 0.865 es *OF* y entre 0.85 y 1 es *G*. Para cada métrica, el modelo asigna una serie de valores cuantitativos de acuerdo con la cualidad obtenida por cada métrica, de la siguiente manera: $G = 8.5$, $OF = 6.0$, $F = 5.5$, $UF = 5.0$ y $P = 2.5$, estableciéndose un índice (*score*) de desempeño descrito por la siguiente expresión:

$$Score = 8.5(nG) + 6.0(nOF) + 5.5(nF) + 5.0(nUF) + 2.5(nP) \quad (2.104)$$

Donde, nG , nOF , nF , nUF y nP indican el número de cualidades parciales obtenidas por el modelo, de acuerdo con cada una de las métricas utilizadas, para evaluar su desempeño. La identificación, finalmente, queda dada por:

$$ID = \frac{score}{NT} \times 100 \quad (2.105)$$

Donde NT es el máximo *score* posible que se pueda obtener.

B. Modelo Neuronal ANFIS

De acuerdo con los diagramas de DACP y DAC mostrados en la Figura 2.17, el modelo neuronal ANFIS que se propone en este trabajo posee el mismo número de entradas definido para la red neuronal MADALINE. Cada salida de la red neuronal corresponde con cada una de las variables que se quieren controlar, donde las entradas son los retardos de cada variable. De esta manera, la identificación del sistema dinámico mediante ANFIS toma la forma ilustrada en la Figura 2.18.

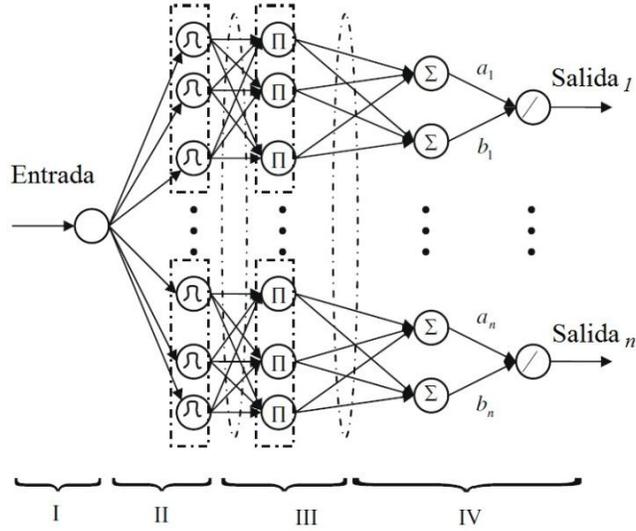


Figura 2.18. Estructura ANFIS para el sistema de identificación.
Fuente: Tomado de (Azadeh et al, 2011).

De manera formal, esta red neuronal se puede definir como sigue:

$$y r_m = C_{jm} S_{jn} = C_{jm} \cdot e^{-\frac{1}{2} \left(\frac{\|XC_{j,i} - X_i\|}{R_j} \right)^2} \quad (2.106)$$

Donde:

$y r_m$: Representa el modelo para cada variable de salida.

$XC_{j,i}$: Indica el número de conjuntos difusos j correspondiente a cada variable de entrada i . Para sistemas acoplados como en el caso del ROV, estos valores de los centroides son comunes a todas las entradas.

R_j : Indica el tamaño de cada uno de los conjuntos difusos j . Al igual que en el caso de los centroides, los radios son comunes al conjunto de entradas al modelo.

$C_{j,m}$: Indica los pesos de salida del modelo neuro-difuso para j de acuerdo con la variable dinámica m .

S_{jn} : Indica los valores de salida normalizados para cada una de las neuronas que conforma la capa oculta del modelo ANFIS, es decir,

$$S_{jn} = \frac{S_j}{S_1 + S_2 + \dots + S_{ne}} \quad (2.107)$$

Siendo ne el número de conjuntos difusos multidimensionales que dan cubrimiento al espacio de solución del problema. De esta manera, el modelo neuro-difuso ANFIS configura un modelo Takagi-Sugeno de primer orden, teniendo en cuenta que la conformación de los conjuntos difusos, que componen las variables de entrada del antecedente de las reglas, es obtenido por medio de una descomposición cartesiana de los *clusters* que se forman en la capa oculta. En la Figura 2.19, se puede observar la forma de un *cluster* que se obtiene en la capa

oculta de un modelo ANFIS, para el caso en el que el modelo considera dos variables de entrada.

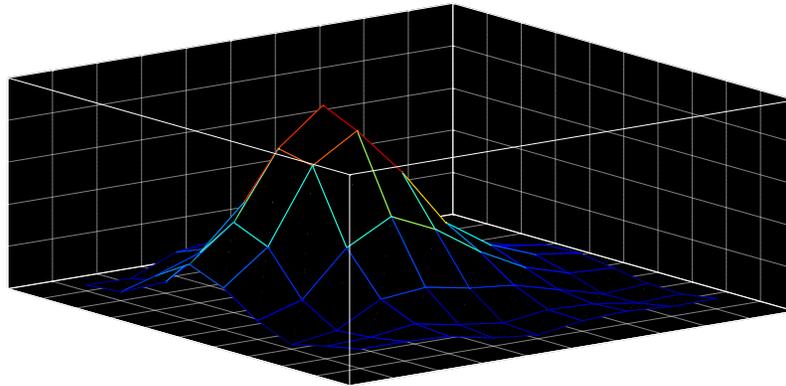


Figura 2.19. Forma de los clusters en la capa oculta del modelo de identificación ANFIS en el espacio R^2
Fuente: Autores del proyecto, 2012.

C. Procedimiento General de Identificación

Para la identificación general de un sistema dinámico acoplado de tipo estocástico conformado en un espacio R^6 (6 variables), se debe seguir de forma general el siguiente procedimiento:

– *Paso 1: Organización de la base de entrenamiento*

La estructura de la base de entrenamiento está dada de acuerdo con la estructura del vector de entrada al modelo de identificación, tal y como se describe en la expresión (2.102). De manera similar, el modelo incorpora 18 columnas adicionales, 6 de las cuales indican los valores de referencia para cada una de las variables de respuesta del sistema $yd_{m,k}$, otras 6 columnas muestran los resultados arrojados por el modelo para cada una de las variables luego del proceso de identificación $yr_{m,k}$, y las últimas 6 columnas muestran el error del modelo de identificación frente a los valores de referencia, el cual queda definido como:

$$er_{m,k} = (yd_{m,k} - yr_{m,k}) \quad (2.108)$$

Donde, $er_{m,k}$ indica el error simple con respecto a cada una de las variables de salida m y $yd_{m,k}$ indica el valor deseado de aprendizaje para cada instante k de identificación, de acuerdo con cada uno de las variables del sistema m .

– *Paso 2: Generación de los componentes del modelo neuronal de identificación*

De acuerdo con la estructura del modelo de identificación ANFIS, es necesario en primera instancia, la generación de forma aleatoria de las componentes de los *clusters* que conforman la capa oculta del modelo, así como los pesos que conectan los *clusters* con cada una de las variables de salida. Para este trabajo se generó la siguiente rutina:

$$XC_{j,i} = -1 + 2 * Aleatorio\{\dots\}$$

$$R_j = 2 * Aleatorio\{\dots\}$$

$$C_{j,m} = -1 + 2 * Aleatorio\{\dots\}$$

– Paso 3: Proceso de Aprendizaje

De acuerdo con la base de entrenamiento, y con la estructura del modelo neuro-difuso de tipo ANFIS, el proceso de aprendizaje inicia con el ingreso de cada uno de los vectores obtenidos para cada instante de tiempo del proceso de identificación del sistema. Por cada vector de entrada, el modelo procede con la actualización de sus pesos y conexiones, teniendo en cuenta la *Regla Delta Generalizada*, la cual queda definida para los pesos de salida y el tamaño de los conjuntos difusos, de la siguiente manera:

$$C_{j,m}^{k+1} = C_{j,m}^k - \alpha \frac{\partial er_{m,k}}{\partial C_{j,m}^k} \quad (2.109)$$

$$R_{j,m}^{k+1} = R_{j,m}^k - \alpha \frac{\partial er_{m,k}}{\partial XC_{j,i,k}} \quad (2.110)$$

Donde α indica el factor de aprendizaje del modelo. Para la actualización de las componentes que conforman cada uno de los *clusters* ubicados en la capa oculta, se debe llevar a cabo una consolidación de los errores de las neuronas en la capa oculta, en términos de cada una de las señales de salida:

$$h_j = \sum_{m=1}^6 \{(C_{j,m})(er_{m,k})\} \quad (2.111)$$

Donde h_j indica el error asociado a cada una de las neuronas ocultas j que conforman el modelo. De esta manera, la actualización de los componentes relacionados con los centroides está determinada igualmente por la *Regla Delta Generalizada*:

$$XC_{j,i,k+1} = XC_{j,i,k} - \alpha \frac{\partial h_j}{\partial XC_{j,i,k}} \quad (2.112)$$

Así, de acuerdo con las ecuaciones (2.106), (2.108), (2.111) y (2.112), la actualización de los componentes asociados a los centroides queda definida por:

$$XC_{j,i,k+1} = XC_{j,i,k} + \alpha * \sum_{m=1}^{NS} C_{j,m}^2 * S_j * \left(\frac{X_i - XC_{j,i}}{R_j^2} \right) \quad (2.113)$$

Donde NS indica el número de salidas del modelo de identificación. Por lo tanto, la actualización del tamaño y forma de los *clusters* que conforman la capa oculta del modelo neuronal, de acuerdo con (2.110) y (2.113) puede expresarse como:

$$R_{j,k+1} = R_{j,k} + \alpha * \sum_{m=1}^{NS} C_{j,m}^2 * er_{m,k} * S_j * \frac{(X_i - XC_{j,i})^2}{R_j^2} \quad (2.114)$$

Es importante anotar que este proceso de actualización se lleva a cabo para cada vector que conforma cada uno de los instantes de tiempo k obtenidos de la identificación. Este proceso se ejecuta hasta un número de iteraciones donde se cumpla con una cota de error, la cual está definida en términos del error cuadrático medio sobre la totalidad de los datos, el cual comúnmente se define como:

$$ERS_m = \frac{1}{2} \sum_{k=1}^{ND} er_{m,k}^2 < 0.05 \quad (2.115)$$

Donde ND indica el número de datos de identificación.

2.4.3 Perturbación del sistema

A. *Perturbación derivada del proceso Ornstein-Uhlenbeck*

Las perturbaciones consideradas para el sistema ROV se derivan de la utilización de un proceso estocástico con reversión a la media conocido como Ornstein-Uhlenbeck (Gillespie, 1996), debido principalmente a que los modelos con reversión a la media evitan que el sistema llegue a ser inestable con respecto a las perturbaciones a lo largo del tiempo. El proceso de Ornstein Uhlenbeck (O-U) es frecuentemente usado en estudios de modelado de sistemas observables y no observables por ser atractivamente dinámico en términos de análisis estocástico (Hu et al., 2010). Particularmente en este estudio, el proceso de Ornstein-Uhlenbeck introduce ruido al sistema en orden de estudiar sus efectos sobre la interacción. Este ruido podría representar una influencia aleatoria a un cambio en los movimientos del ROV. De esta manera, el sistema estará sujeto a un proceso en el cual un comportamiento inesperado afectará la dinámica del sistema y perturbará la señal de salida. La simulación en Matlab de este proceso unidimensional de Ornstein Uhlenbeck está dado por:

$$dX_t = \gamma X_t dt + \sqrt{2D} dw_t \quad (2.116)$$

En la Figura 2.20 se presenta una señal aleatoria con componentes en todas las frecuencias de la señal, la cual fue generada a partir del proceso Ornstein-Uhlenbeck. Este ruido es agregado a las variables de salida del sistema ROV, modificando los valores según las unidades correspondientes a cada una.

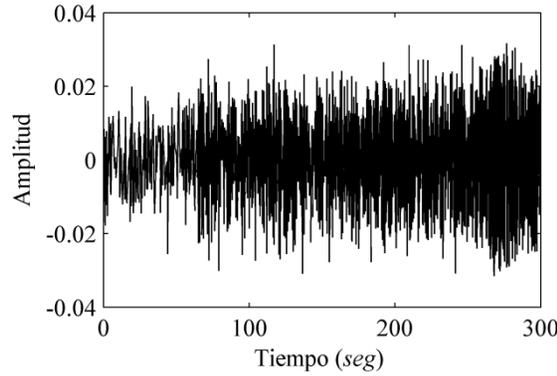


Figura 2.20. Ruido Ornstein-Uhlenbeck aplicado a las variables de salida del ROV.
Fuente: Autores del proyecto, 2012.

B. Cancelación de las perturbaciones

Uno de los elementos que determina el comportamiento de un sistema dinámico de tipo estocástico está directamente relacionado con el manejo de las perturbaciones. De acuerdo con la representación del sistema en espacio de estados, las perturbaciones pueden ser tenidas en cuenta para el modelamiento, sin embargo, las matrices que conforman el par de controlabilidad y observabilidad pasan por alto el comportamiento de las perturbaciones del sistema, haciendo en muchos casos que los sistemas presenten inestabilidad por desconocimiento de las mismas, o porque en el sistema dinámico las perturbaciones son inherentes a la entrada, al sistema mismo, o a la salida, hecho que aumenta el problema de inestabilidad. Para este estudio, se plantean tres modelos con el fin de incorporar el comportamiento de las perturbaciones al controlador. Estos modelos son los siguientes:

1. Cancelación de las perturbaciones por modelo interno.
2. Cancelación de las perturbaciones por modelo neuronal independiente.
3. Cancelación de las perturbaciones por modelos de referencia MRAC.

– Cancelación de las perturbaciones por modelo interno

Este modelo cancela las perturbaciones mediante la utilización de una red neuronal de tipo ANFIS, tomando la forma estructural de un modelo ARMA (Stella, Begusic, & Russo, 2006):

$$y_{r,m,k} = C_{j,m} f(XC_{j,i} X_{iT}) \quad (2.117)$$

Donde $X_{i,T}$ representa el vector de entrada total del sistema, el cual incorpora tanto el comportamiento del sistema como el de las perturbaciones. Este vector se denota como:

$$X_{i,T} = [X_{e,i} \ X_i] \quad (2.118)$$

Aquí, $X_{e,i}$ es el vector de perturbación del sistema en términos de los errores obtenidos a la salida, y se integra con el vector X_i , el cual sólo considera las entradas inherentes a los retardos

de las variables que describen el comportamiento del sistema dinámico. Así, el vector de perturbaciones se puede denotar como:

$$X_{e,i} = [e_{k-ne,1}, e_{k-ne,2}, \dots, e_{k-1,5}, \dots, e_{k-1,m}] \quad (2.119)$$

Donde, ne indica el número de retardos considerados para el error en las m señales de salida del sistema acoplado MIMO.

– *Cancelación de las perturbaciones por modelo independiente*

Tomando en cuenta la estructura del modelo ANFIS, la identificación de perturbaciones mediante un modelo neuronal independiente toma la siguiente forma (Chang & Shyu, 2003):

$$y_{r_{k,m}} = y_{r_{k,m,t}} + e_{k,m} \quad (2.120)$$

Donde:

$y_{r_{k,m}}$: Representa la salida del modelo m luego de la cancelación del ruido.

$y_{r_{k,m,t}}$: Representa la respuesta del sistema real.

$e_{k,m}$: Indica el modelo neuronal que permite la cancelación de las perturbaciones por efecto de las observaciones incompletas. Este modelo se define como sigue:

$$e_{k,m} = C_{j,e,m} f(XC_{j,i}, X_{i,t}) \quad (2.121)$$

Donde:

$X_{i,t}$: Representa el vector de entrada total, teniendo en cuenta tanto los valores autorregresivos del error, y los retardos de cada una de las señales de salida del modelo, similarmente como se presenta la expresión (2.118).

$C_{j,e,m}$: Representa los valores de salida del modelo independiente de la red neuronal que permite estimar el error con respecto a la salida teórica del sistema.

Es de anotar que el modelo independiente puede ser modelado estructuralmente como un modelo autorregresivo. Sin embargo para la aplicación del control propuesto, el cual es de tipo autoajutable, se requieren mecanismos de adaptación que son incluidas de forma natural por las redes ANFIS o el modelo de *Takagi Sugeno*.

– *Cancelación de las perturbaciones por modelos de referencia MRAC*

La cancelación de perturbaciones por modelo externo, se hace generalmente mediante la utilización de Controladores Adaptativos con Modelo de Referencia (MRAC), los cuales toman el comportamiento teórico del sistema, para que el controlador siga el de un modelo de referencia predeterminado, ayudado de una alta capacidad de adaptación y aprendizaje (Castillo & Melin, 2004). De esta forma, el modelo MRAC hace que el sistema incorpore a su dinámica la cancelación interna del error. El esquema de este modelo de cancelación se presenta en la Figura 2.21, donde se puede observar que el error de control se estima respecto del modelo de referencia, el cual es similar al modelo interno del sistema, puesto que hay una

gran cercanía entre el modelo de referencia y el modelo autorregresivo que determina el control. Así, cuando las perturbaciones sean enviadas al modelo de referencia son canceladas, por lo que la respuesta del sistema es muy similar a la del modelo, quedando eliminadas automáticamente las perturbaciones.

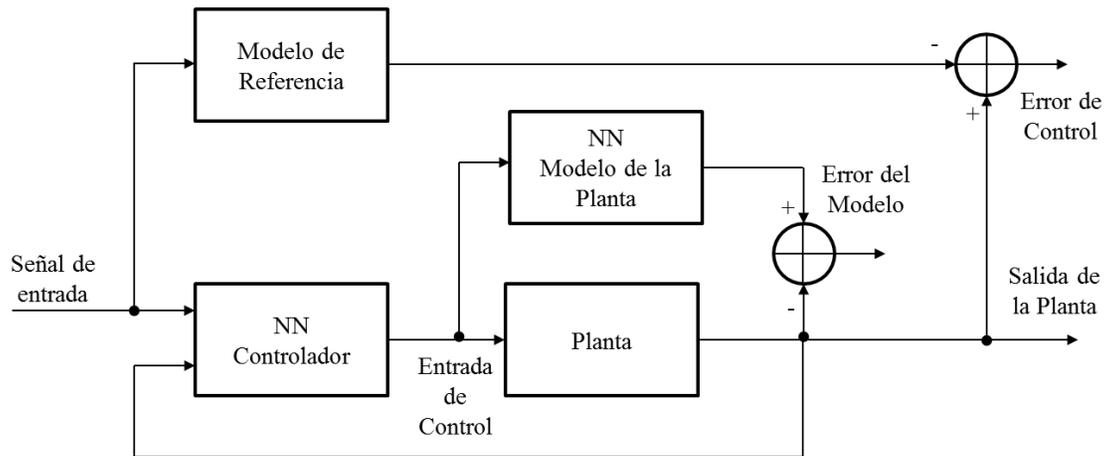


Figura 2.21. Estructura del Modelo de Control por Referencia – MRAC
Fuente: Autores del proyecto, 2012.

2.4.4 Modelo de Control

A partir de los modelos usados para la identificación del ROV y de los principios que rigen el control adaptativo en términos computación neuronal, se obtiene el modelo de control para sistemas acoplados de tipo estocástico con información incompleta, el cual se basa igualmente en la *Regla Delta Generalizada*, que para este caso se puede definir como sigue (Sánchez & Alanis G., 2006):

$$u_{NC,k+1} = u_{NC,k} - \alpha \frac{\partial ert_k}{\partial u_{NC,k}} \quad (2.122)$$

Donde:

NC : Indica el número de señales de control enviadas al sistema acoplado.

$u_{NC,k}$: Denota la señal de control enviada a los actuadores del ROV para el control del sistema.

ert_k : Consolida el error total sobre todas las salidas del sistema acoplado, y se expresa como,

$$ert_k = \sum_{m=1}^{NC} er_{m,k} \quad (2.123)$$

Para llevar a cabo el control del sistema, se proponen dos modelos autorregresivos basados en la estructura de red neuronal de tipo MADALINE y de tipo ANFIS. Para ambos modelos, el control adaptativo está basado en la regla delta generalizada, y la cancelación de perturbaciones se logra mediante modelo interno, debido principalmente al pequeño costo

computacional que exige este tipo de controladores frente a la adaptación. De acuerdo con lo anterior, para el análisis de ambos controladores, se procede inicialmente con el control del sistema, teniendo en cuenta dos configuraciones respecto al *Set Point*:

1. *Configuración Homogénea*: Para la configuración homogénea del *Set Point*, se realiza una serie de pruebas del controlador teniendo en cuenta un mismo *Set Point* para cada una de las variables del sistema. En este caso particular, y debido a que la regla delta generalizada se debe tener en cuenta para cada una de las variables, el controlador experimentará un comportamiento similar en cada esfuerzo de control.
2. *Configuración Heterogénea*: Para la configuración heterogénea, se configura de forma aleatoria cada *Set Point* asociado al sistema, de modo que el comportamiento de las derivadas asociadas con la señal de control sean diferenciales. Es así como esta configuración permite evaluar la controlabilidad del sistema en cualquier punto del funcionamiento del ROV.

A. Análisis del Control MADALINE

Para el análisis del controlador MADALINE, se toma un intervalo de tiempo de 200 *seg*, y el comportamiento se evalúa en términos del *Set Point* de forma homogénea y heterogénea sin cancelación de ruido, así como en términos de la configuración heterogénea con cancelación de ruido. Tal y como se indicó en la Sección 2.4.3, las perturbaciones del sistema son modeladas mediante la utilización del proceso estocástico Ornstein-Uhlenbeck (Gillespie, 1996), considerando que los modelos con reversión a la media evitan que el sistema llegue a ser inestable con respecto a las perturbaciones a lo largo del tiempo.

B. Análisis del Control ANFIS

Para el análisis y la validación del comportamiento del controlador de tipo ANFIS, se llevó a cabo un análisis de la respuesta del sistema en términos de la diferente configuración del *Set Point*. Es decir, una configuración heterogénea sin cancelación de perturbaciones y una configuración heterogénea con cancelación de perturbaciones.

2.4.5 Análisis de estabilidad en sistemas acoplados

Para evaluar la estabilidad de sistemas dinámicos mediante el uso de procesos de adaptación y aprendizaje, como es el caso de los controladores considerados en esta tesis, se propone el análisis de estabilidad mediante funciones candidatas de Lyapunov (Mejía, 2009), que para el caso de sistemas de adaptación y aprendizaje, se definen en términos de la *Regla Delta Generalizada* como sigue (Chen & Hwang, 2006):

$$\frac{\partial e_k^2}{\partial t} = \frac{\partial e_k^2}{\partial y_{r_k}} \frac{\partial y_{r_k}}{\partial u_k} \frac{\partial u_k}{\partial X_{j,i}} \frac{\partial X_{j,i}}{\partial t} \quad (2.124)$$

Así, la regla delta generalizada permite la actualización de los pesos del controlador de la siguiente manera:

$$\frac{\partial XC_{j,i}}{\partial t} = -\alpha \frac{\partial e_k^2}{\partial yr_k} \frac{\partial yr_k}{\partial u_k} \frac{\partial u_k}{\partial XC_{j,i}} \quad (2.125)$$

Remplazando (2.124) en (2.125), entonces se tiene:

$$\frac{\partial e_k^2}{\partial t} = -\alpha e_k^2 \left(\frac{\partial yr_k}{\partial u_k} \right)^2 \left(\frac{\partial u_k}{\partial XC_{j,i}} \right)^2 \quad (2.126)$$

Con lo que finalmente se consigue expresar formalmente la función candidata de Lyapunov en términos de los parámetros y variables que componen el modelo ANFIS:

$$\frac{\partial e_k^2}{\partial t} = -\alpha e_k^2 \|\varphi(u_k, XC_{j,i})\|^2 * \left| \frac{\partial yr_k}{\partial u_k} \right|^2 \quad (2.127)$$

Donde:

α : Indica el factor de estabilidad del sistema de control. Para mantener el comportamiento globalmente atractivo del controlador, el valor de α debe estar definido como $\alpha > 0$.

e_k^2 : Establece el error del sistema de acuerdo con el *Set Point* pre-establecido para cada una de las variables que conforma el sistema dinámico acoplado. Aquí el acoplamiento, está dado en términos de los valores de los centroides que definen cada uno de los conjuntos difusos $XC_{j,i}$.

$\|\varphi(u_k, XC_{j,i})\|$: Indica el factor de sensibilidad que determina el efecto generado por el proceso adaptativo donde son definidos los centroides que conforman la capa oculta del modelo ANFIS en relación con cada una de las señales de control.

$\left| \frac{\partial yr_k}{\partial u_k} \right|$: Factor de sensibilidad en términos de cada una de las variables de salida del sistema.

CAPÍTULO 3

RESULTADOS Y DISCUSIÓN

En este capítulo se muestra un análisis de los resultados obtenidos del marco experimental de la propuesta investigativa identificación y control de sistemas estocásticos con observaciones incompletas mediante modelos neuro-difusos.

El trabajo se realiza con la simulación de la planta que para este caso corresponde a un Vehículo Operado Remotamente, dado su alto grado de no linealidad y complejidad del modelo matemático en su identificación y control. En este sistema las variables de salida son las que representan la posición del ROV, manteniendo el estándar usado para vehículos submarinos, donde los movimientos de rotación y desplazamientos se denotan como: ($x, y, z, roll, pitch, yaw$) garantizando que ningún movimiento quede por fuera de estos 6 grados de libertad. Aquí se realiza la evolución de la posición y la orientación del vehículo en función de las fuerzas que actúan sobre él.

3.1 Resultados de la identificación del sistema

En la Tabla 3.1 se puede observar que el modelo difuso propuesto integrado con el modelo neuronal MADALINE para la identificación del sistema ROV de tipo acoplado logró obtener los máximos valores de *Score* fijados en (Park & Seok, 2007), los cuales fueron presentados en la Sección 2.4.2 de este documento.

	x		y		z		φ		θ		ψ	
FB	-0,00200081	G	0,00195667	G	- 0,00336628	G	0,0002581	G	0,0002581	G	0,00256603	G
NMSE	0,00015747	G	6,0008E-56	G	0,00013806	G	8,5127E-07	G	1,0071E-07	G	8,9787E-05	G
MG	0,99724856	G	1,00208019	G	0,99620902	G	0,99923446	G	1,00025817	G	1,00299076	G
VG	1,00023137	G	1,00006628	G	1,00014873	G	1,00000085	G	1,00000001	G	1,00009753	G
FAC2	1	G	1	G	1	G	1	G	1	G	1	G
IOA	0,99884598	G	0,99890643	G	0,99915236	G	0,97932102	G	0,9671697	G	0,99949604	G
UAPC2	-0,001	G	-0,003	G	- 0,00536069	G	0	G	-1,0001E-05	G	0,00500862	G
MRE	-0,00287119	G	0,00204492	G	- 0,00076626	G	-0,00076626	G	0,00025808	G	0,00293771	G
ID	100		100		100		100		100		100	

Tabla 3.1. Identificación MADALINE para cada una de las variables que determinan la dinámica del ROV.

Fuente: Autores del proyecto, 2012.

Es resaltable que la varianza general de los datos estuvo cercana a la unidad, significando esto que los resultados arrojados por el modelo de identificación estuvieron cercanos a los valores de referencia. Sin embargo, también se aprecia que la identificación generó en algunas ocasiones sobre-estimaciones en las componentes x, z y $roll$. Por su parte, el índice de predicción FAC2, estuvo cercano a la unidad, lo que muestra que un controlador diseñado en términos de una estructura neuronal de este tipo, permite mantener el sistema en límites de

funcionamiento aceptables, sobretodo en casos en los cuales los sistemas están expuestos a perturbaciones. En términos de identificación, esto muestra la calidad del modelo frente a la estimación de los datos de referencia. De acuerdo con el índice UAPC2, se puede decir que el modelo logró un valor cercano a cero, lo que corrobora que un controlador basado en esta estructura, se puede adaptar fácilmente a cambios inesperados en las condiciones de operación del ROV (Chin, Lau, Low, & Seet, 2006).

En relación al mecanismo de identificación ANFIS, se obtuvo una tabla de *Score* similar a la obtenida para MADALINE (ver Tabla 3.1), con la diferencia de que no se generaron sobreestimaciones para ninguna de las componentes dinámicas del ROV. Esta identificación usó una onda seno para generar la base de entrenamiento de una red con 10 capas ocultas, 6 señales de salida ($x, y, z, \varphi, \theta, \psi$) y 18 señales de entrada, definidas como:

$$\begin{aligned}
 &u_1(k-1), u_2(k-1), u_3(k-1), u_4(k-1), u_5(k-1), u_6(k-1) \\
 &x(k-1), y(k-1), z(k-1), \varphi(k-1), \theta(k-1), \psi(k-1) \\
 &x(k-2), y(k-2), z(k-2), \varphi(k-2), \theta(k-2), \psi(k-2)
 \end{aligned}$$

Desde la Figura 3.1 a la Figura 3.6 se presentan los resultados de identificación del ROV.

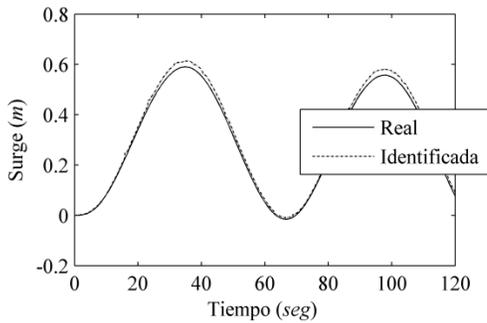


Figura 3.1. Señal real e identificada para x (*Surge*).
Fuente: Autores del proyecto, 2012.

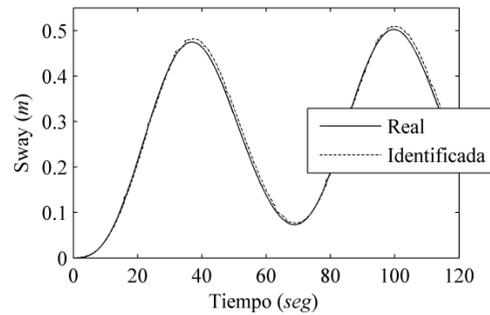


Figura 3.2. Señal real e identificada para y (*Sway*).
Fuente: Autores del proyecto, 2012.

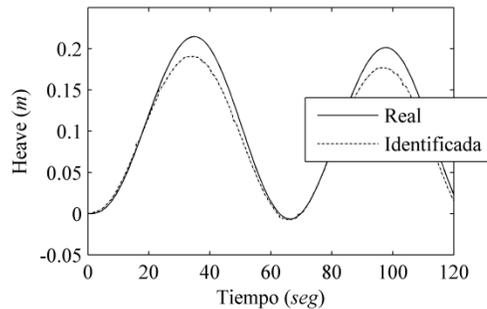


Figura 3.3. Señal real e identificada para z (*Heave*).
Fuente: Autores del proyecto, 2012.

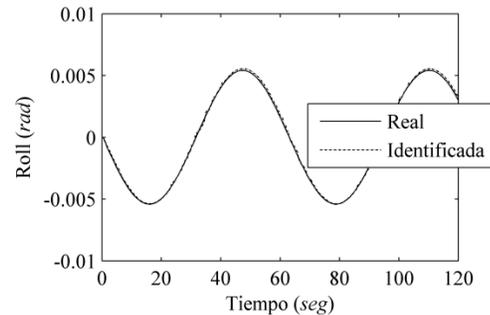


Figura 3.4. Señal real e identificada para φ (*Roll*).
Fuente: Autores del proyecto, 2012.

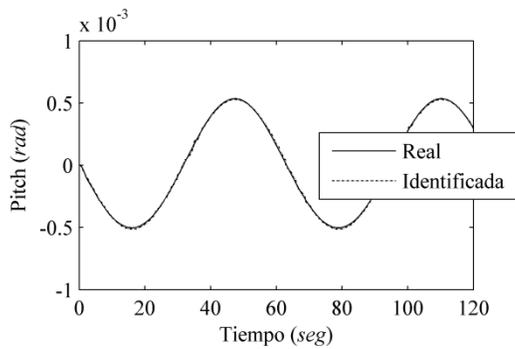


Figura 3.5. Señal real e identificada para θ (Pitch).
Fuente: Autores del proyecto, 2012.

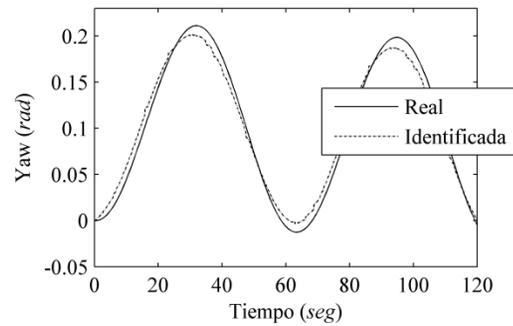


Figura 3.6. Señal real e identificada para ψ (Yaw).
Fuente: Autores del proyecto, 2012.

Se aprecia que las señales reales y las identificadas tienen la misma tendencia, frecuencia y fase, aunque con un pequeño margen de error en la amplitud. El error de identificación corresponde a menos del 10% de la amplitud en el peor de los casos, lo cual en términos de estabilidad del sistema es significativamente pequeño, puesto que este margen de amplitud permite sin problemas las acciones de respuesta del controlador cuando la estabilidad está siendo afectada. Sin embargo, este margen de error de amplitud afecta proporcionalmente la precisión del controlador en cuanto al error de estado estacionario.

3.2 Resultados en la reducción de perturbaciones

De la Figura 3.7 a la 3.12 se observa el desempeño de la estructura mostrada en la Figura 2.21, la cual se usó para mover el ROV de una posición inicial $(0, 0, 0, 0, 0, 0)$ a una posición final $(15, 10, 5, 0, 0, \pi/6)$, de acuerdo con el vector de salidas $(x, y, z, \varphi, \theta, \psi)$. Así, las variables de salida, luego de ser perturbadas con el ruido Ornstein-Uhlenbeck, fueron limpiadas con la estructura propuesta en este trabajo en la sección 2.4.

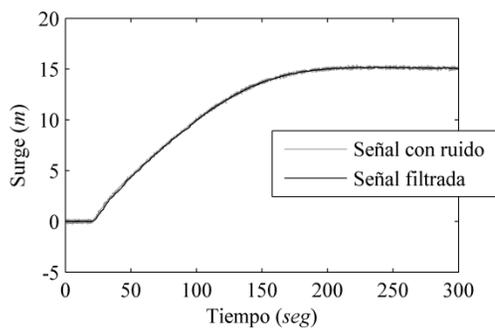


Figura 3.7. Acción del filtro en x (Surge).
Fuente: Autores del proyecto, 2012.

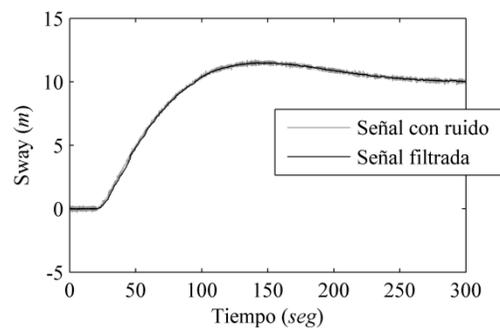


Figura 3.8. Acción del filtro en y (Sway).
Fuente: Autores del proyecto, 2012.

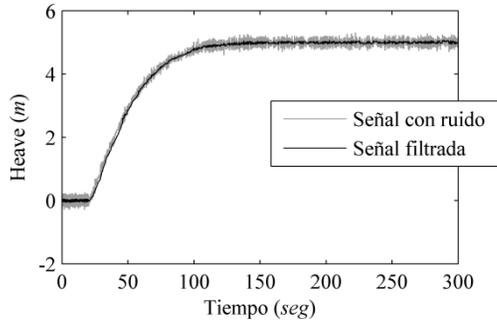


Figura 3.9. Acción del filtro en z (*Heave*).
Fuente: Autores del proyecto, 2012.

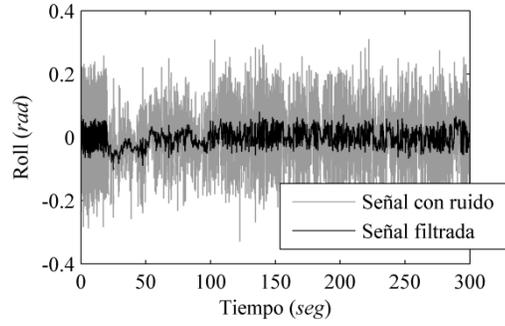


Figura 3.10. Acción del filtro en φ (*Roll*).
Fuente: Autores del proyecto, 2012.

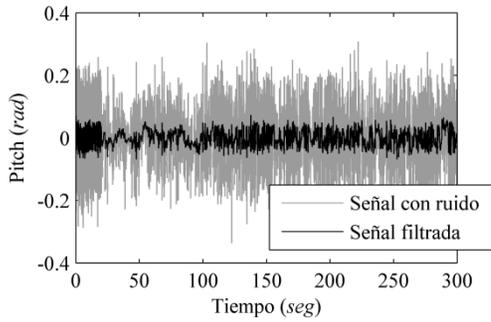


Figura 3.11. Acción del filtro en θ (*Pitch*).
Fuente: Autores del proyecto, 2012.

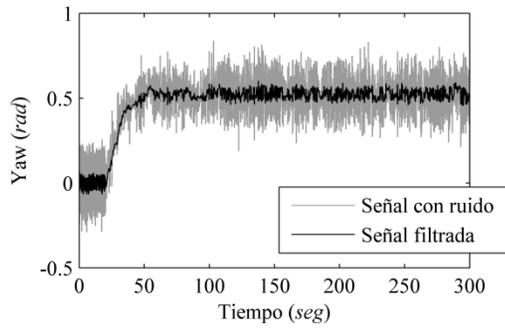
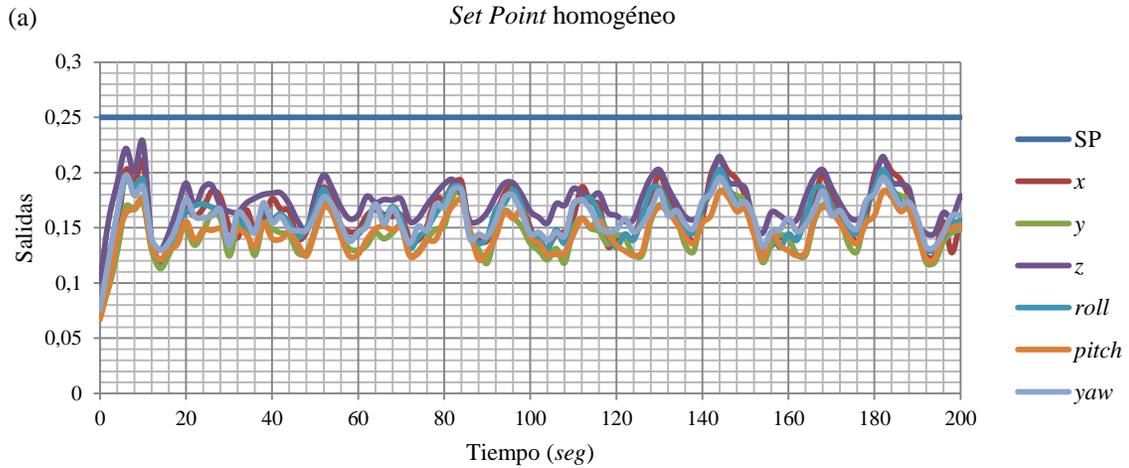


Figura 3.12. Acción del filtro en ψ (*Yaw*).
Fuente: Autores del proyecto, 2012.

3.3 Análisis del control MADALINE



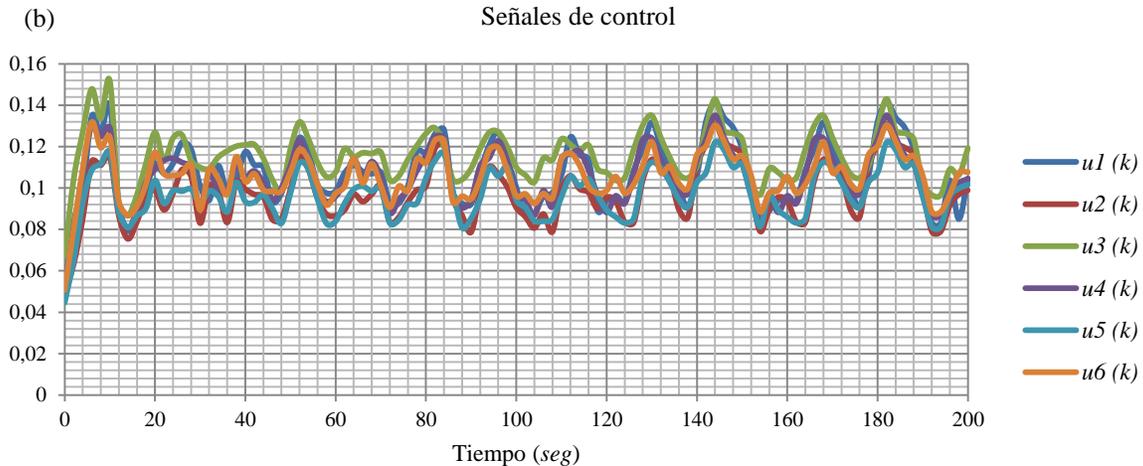


Figura 3.13. Control MADALINE para Set Point homogéneo sin cancelación de perturbaciones.

(a) Respuesta del sistema (b) Comportamiento de las señales de control.

Fuente: Autores del proyecto, 2012.

Todas las figuras están en la misma escala dado que las señales tienen las mismas dimensiones. Como el *Set Point* es heterogéneo, la referencia para cada una de las variables es diferente como se puede observar en las gráficas 3.14(a) y 3.15(a).

Tomando en consideración la configuración homogénea del *Set Point*, sin cancelación de las perturbaciones, el controlador logró llevar el ROV a un cuarto del rango total del *Set Point* para cada una de las variables de salida. En la Figura 3.13 se observa que la respuesta del sistema presenta un error en estado estable con respecto al *Set Point* homogéneo, además de las perturbaciones debidas a la inclusión del proceso estocástico que se identifica con los movimientos inesperados de las corrientes acuáticas y las incertidumbres inherentes del sistema. Al no considerar la cancelación de las perturbaciones, la señal de control se comporta de forma similar a la respuesta del sistema, lo que muestra que las perturbaciones afectan de igual manera la señal de control. En cuanto a la configuración heterogénea del *Set Point*, sin cancelación de perturbaciones, en la Figura 3.14 se observa que el controlador lleva el sistema a un estado con error en estado estable proporcional al *Set Point* heterogéneo aleatorio propuesto, de forma que el sistema puede ser llevado a cualquier estado deseado en términos proporcionales del *Set Point*, lográndose así la controlabilidad del sistema.

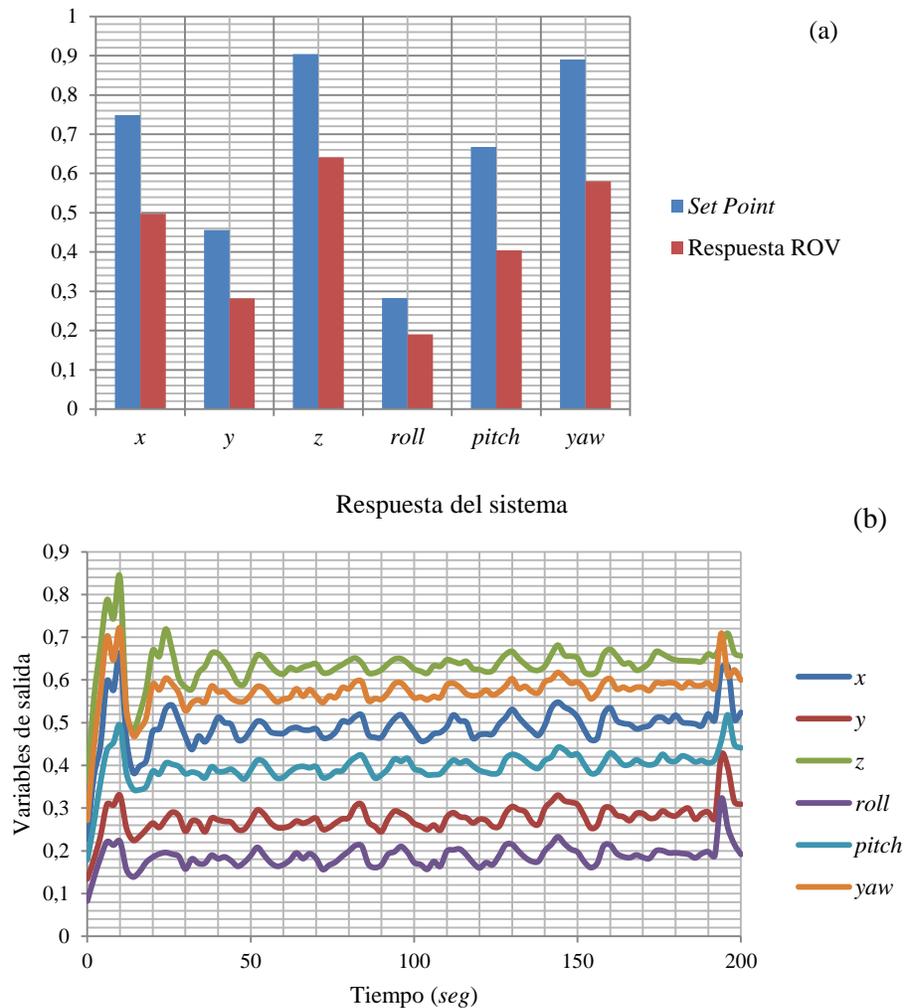


Figura 3.14. Control MADALINE para Set Point heterogéneo sin cancelación de perturbaciones.
 (a) Comportamiento general del sistema frente al *Set Point* (b) Respuesta del sistema.
 Fuente: Autores del proyecto, 2012.

Debido al rizado que presenta la respuesta del sistema frente a cada *Set Point*, se aplica un proceso de cancelación de perturbaciones asociada a la configuración de *Set Point* heterogéneo, dado que estas alteraciones son influenciadas por las observaciones incompletas. Así, el controlador implementa una realimentación de los errores que van apareciendo en el sistema, arrojando como resultado el suavizado de cada una de las respuestas obtenidas del ROV, tal y como se muestra en la Figura 3.15, lo cual es muy deseado para ciertas aplicaciones submarinas, como es la adquisición de imágenes y video, donde el ROV debe llegar a cada *Set Point* pre-establecido con el mínimo rizado en su respuesta.

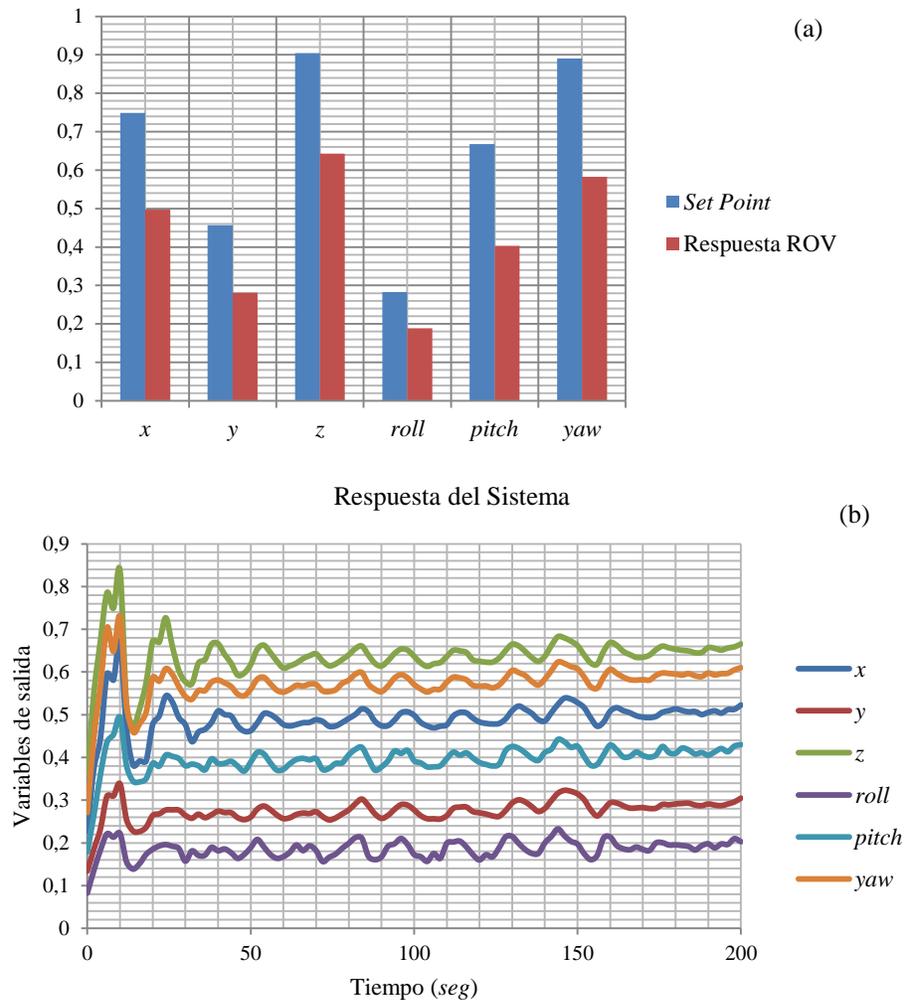


Figura 3.15. Control MADALINE para Set Point heterogéneo con cancelación de perturbaciones. (a) Comportamiento general del sistema frente al *Set Point* (b) Respuesta del sistema. Fuente: Autores del proyecto, 2012.

Estos resultados muestran la capacidad que tienen los modelos neuronales lineales del tipo MADALINE para configurar un control por adaptación capaz de absorber perturbaciones de naturaleza estocástica. Sin embargo, se evidencia una desventaja importante en relación con el error en estado estable que se mantuvo en la misma magnitud tanto para la configuración sin cancelación como con cancelación de perturbaciones (Ver Figuras 3.14a y 3.15a).

3.4 Análisis del control ANFIS

Ahora con el ánimo de analizar la configuración de control ANFIS para *Set Point* heterogéneo sin cancelación de perturbaciones, en la Figura 3.16 se aprecia la respuesta controlada del ROV. Es notable el proceso de adaptación que el modelo ANFIS experimenta en un principio, dado que todos sus elementos son inicializados aleatoriamente. Este hecho produce que la salida del sistema refleje cierto nivel de desorden en términos de convergencia durante las primeras iteraciones. Luego de lograrse el autoajuste de los parámetros, el modelo ANFIS logra llevar el sistema al *Set Point* heterogéneo de una manera más amortiguada que la

observada con el modelo MADALINE. La razón puede deberse al tipo de funciones base usadas por el controlador ANFIS y la adaptación que el modelo realiza sobre el comportamiento del sistema. Sin embargo, y a pesar de que el modelo alcanza la estabilidad, la respuesta tiene un comportamiento oscilatorio alrededor del *Set Point*, debido a las perturbaciones, razón por la cual se requiere la inclusión de un filtro de cancelación.

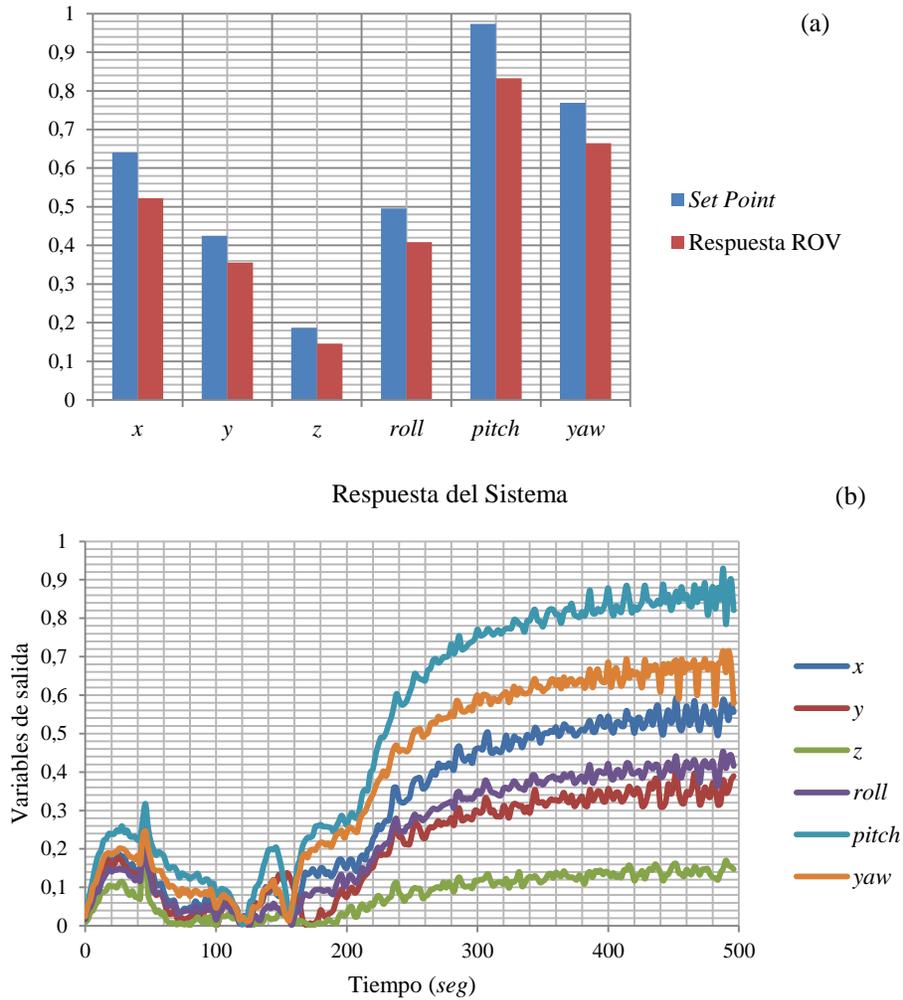


Figura 3.16. Control ANFIS para Set Point heterogéneo sin cancelación de perturbaciones.
 (a) Comportamiento general del sistema frente al *Set Point* (b) Respuesta del sistema.

Fuente: Autores del proyecto, 2012.

En la Figura 3.17 se observa que el controlador ANFIS para un *Set Point* heterogéneo con cancelación de perturbaciones, similar que en el caso anterior, en sus primeras iteraciones se refleja el proceso de adaptación y aprendizaje asociado al ajuste de los centroides que conforman los conjuntos difusos de las variables de entrada. Luego de este proceso, el controlador lleva el sistema al *Set Point* pre-definido, demostrando robustez frente a comportamientos estocásticos. Al igual que los controles anteriores, el sistema presenta error en estado estable con respecto al *Set Point*, sin embargo asegura la controlabilidad sobre el sistema, además de atenuar las perturbaciones del sistema provenientes de las observaciones

incompletas. La respuesta obtenida con el sistema de control integrado por el modelo ANFIS y el modelo de cancelación de ruido, además de ser menos oscilante, refleja el seguimiento del *Set Point* heterogéneo con mayor precisión al obtenido con el modelo MADALINE.

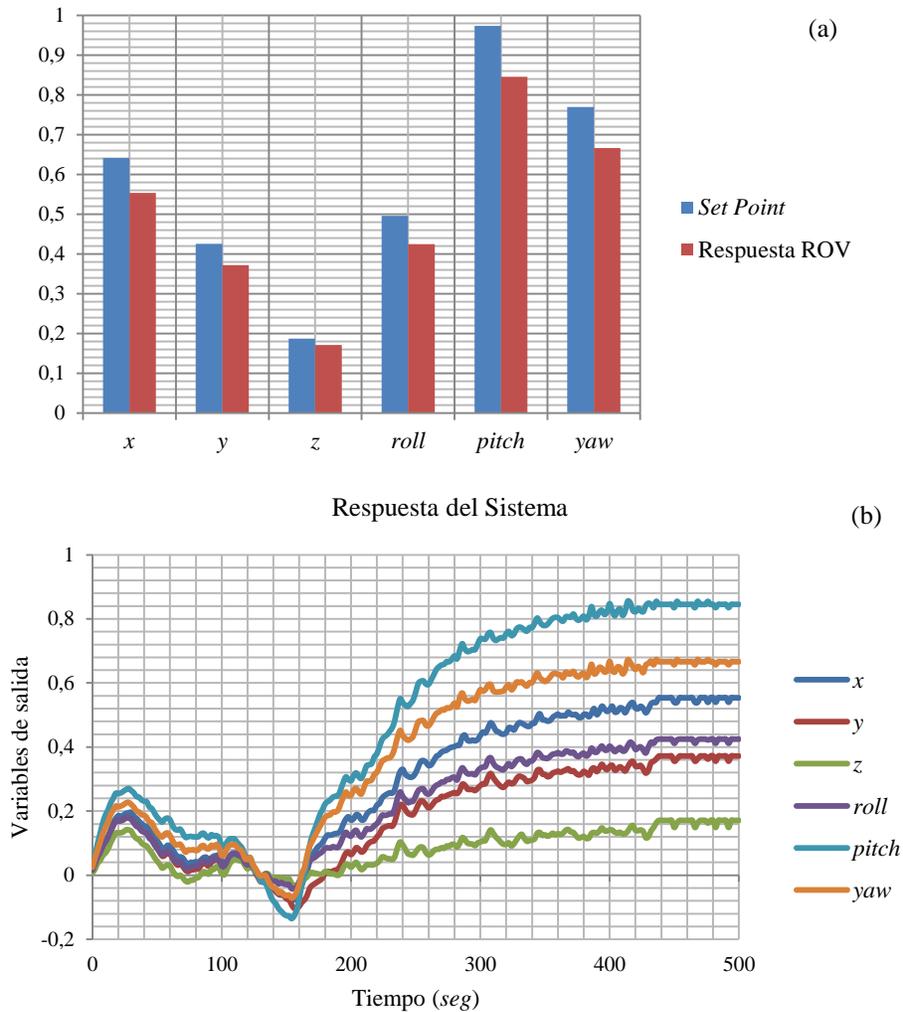


Figura 3.17. Control ANFIS para Set Point heterogéneo con cancelación de perturbaciones.
 (a) Comportamiento general del sistema frente al Set Point (b) Respuesta del sistema.
 Fuente: Autores del proyecto, 2012.

Usando los valores obtenidos para la relación señal a ruido (SNR, *Signal to noise ratio*) entre las variables de salida ilustradas en las Figuras 3.16 (sin cancelación) y la 3.17 (con cancelación), se construye la Tabla 3.2 donde se muestra la mejora en decibelios de la respuesta del sistema de control que integra la cancelación del ruido.

Conf.Hetero.ANFIS.(SC)	Conf.Hetero.ANFIS.(CC)
18,7	25,3
16,2	24,1
14,9	23,7
17,1	24,8
19,2	25,9
18,8	25,6

Tabla 3.2. Valores SNR en decibeles.

Fuente: Autores del proyecto, 2012.

3.5 Análisis de estabilidad del sistema controlado con ANFIS

Debido a que los centroides del modelo son comunes para el sistema ANFIS de tipo MIMO, cada una de las señales de control se puede evaluar frente a las salidas del modelo. Tomando en cuenta el análisis de estabilidad presente en la sección 2.4.5, desarrollando la expresión (2.127) y comprobando los valores α , se obtiene la estabilidad del sistema. Por medio de las explicaciones que reporta la literatura respecto al análisis de estabilidad y computando cada uno de los términos de la expresión, se encontró que $\alpha > 0$. Este resultado indica que el modelo neuro-difuso ANFIS propuesto lleva el sistema a un estado globalmente atractivo frente a la función de error que determina la función candidata de Lyapunov.

CAPÍTULO 4

CONCLUSIONES

Se propuso una metodología basada en modelos neuro-difusos de tipo ANFIS para la identificación y control de sistemas estocásticos con observaciones incompletas mediante modelos neuro-difusos. El desempeño de identificación del modelo ANFIS se comparó contra un modelo neuronal MADALINE, donde este último generó ocasionalmente sobre-estimaciones en las componentes x , z y $roll$. Estas sobre-estimaciones fueron corregidas por el mecanismo de identificación ANFIS, el cual ofreció un seguimiento con la misma tendencia, frecuencia y fase, aunque se evidenciaron errores de amplitud que fueron considerados significativamente pequeños para aplicaciones de control en móviles subacuáticos. Esta misma comparación se llevó a cabo en términos del desempeño de control, y a diferencia del controlador MADALINE, se pudo observar que el modelo ANFIS tiende a capturar en mejor medida el comportamiento del modelo, gracias a las funciones que definen los conjuntos difusos asociados a cada variable lingüística de entrada al modelo. Asimismo, la inferencia difusa permitió que el sistema ANFIS disminuyera el error de estado estacionario en relación al error obtenido con el modelo MADALINE, debido a que las funciones de entrada funcionan como filtros de las señales perturbadas y esto ayuda a que el sistema sea más efectivo al seguimiento del Set Point. Sin embargo, fue notable la necesidad de integrar al modelo ANFIS el sistema de cancelación de perturbaciones externas para lograr reducir el rizado indeseable, puesto que existen ciertas aplicaciones subacuáticas que exigen el alcance de cada Set Point con el mínimo movimiento posible.

Se analizó matemáticamente la operación de movimiento del ROV, en orden de caracterizar el modelo en términos de sus variables dinámicas, donde fueron consideradas las fuerzas y torques de los propulsores, las fuerzas y torques de gravedad y flotación, la cinemática submarina, la aceleración y posición relativa a tierra de forma lineal y angular, con lo que se halló finalmente la ecuación dinámica del movimiento. El modelo obtenido fue simulado con el paquete Simulink® de Matlab© R2010b, a fin de obtener la respuesta del sistema en lazo abierto y analizar el grado de estabilidad de cada una de las variables de salida. De acuerdo con las simulaciones, se encontró que este sistema de 6 grados de libertad, puede reducirse a 4, debido a que tanto el roll como el pitch son de manera natural estables, y esto no se aleja de lo que la literatura ha reportado en estudios anteriores. Las componentes en x (*surge*) y en y

(*sway*) son marginalmente estables, y la componente en z y el *yaw* son inestables en el sentido de Lyapunov. De acuerdo con el modelo matemático del ROV, este sistema es un MIMO acoplado con dos variables de salida inestable e interactuantes, por lo que el control del sistema integral exigió la captura de la dinámica intrínseca cuando además fueron incluidas perturbaciones de naturaleza estocástica.

Mediante la obtención de los diagramas de autocorrelación (DAC) y autocorrelación parcial (DACP) por cada una de las señales de respuesta del ROV se logró determinar tanto la estructura del modelo de identificación, así como el grado del mismo. Aunque el modelo neuronal MADALINE y el modelo neuro-difuso ANFIS mostraron alto desempeño de identificación, la estructura ANFIS tomó ventaja de la inferencia difusa para adaptarse más fácilmente a la dinámica operativa del ROV. El sistema de identificación se integró a un filtro de perturbaciones estocásticas y se logró sobreponer la información incompleta del sistema de manera suficiente que no afectara la operación del controlador en términos de estabilidad del sistema.

Finalmente, gracias a la capacidad de adaptación y conocimiento lingüístico de los modelos neuro-difusos, se logró un desempeño de control con resultados favorables para las aplicaciones operativas del ROV. Se destaca la facilidad con que los modelos neuro-difusos pueden ser altamente potenciados a través de la integración con otros esquemas de procesamiento, e.g., aprovechando las ventajas que ofrece el análisis estadístico, evolutivo o la teoría de información, a fin de estructurar soluciones más robustas y confiables, aunque no siempre pueda asegurarse la fácil implementación. En general, se puede concluir que estos modelos cuentan con las características dinámicas suficientes para superar los inconvenientes inherentes a la dinámica estocástica, en sistemas que además tienen el inconveniente de no contar con la totalidad de la información.

CAPÍTULO 5

TRABAJO FUTURO

Con la metodología propuesta basada en modelos neuro-difusos de tipo ANFIS para la identificación y control de sistemas estocásticos con observaciones incompletas mediante modelos neuro-difusos, el cual fue comparado contra el modelo neuronal MADALINE. Aunque el modelo ANFIS logra un mejor desempeño y logra obtener un mejor comportamiento del modelo, debido a las funciones que definen los conjuntos difusos de sus variables lingüísticas de entrada al modelo, es necesario integrar al modelo ANFIS un sistema de cancelación de perturbaciones externas para lograr reducir el rizado indeseable, esto debido a que existen aplicaciones subacuáticas que exigen el alcance de cada Set Point con el mínimo movimiento posible. De acuerdo con esto, se plantea como trabajo futuro la inclusión de algoritmos de optimización genética a esta plataforma de control para hacer más efectivo el sistema en términos de movimiento y trayectoria.

Aunque se pudo lograr un desempeño de control con resultados muy favorables para las aplicaciones y dinámica de los vehículos operados remotamente, quedan asuntos pendientes en términos de mejorar el error de estado estable y las perturbaciones generadas por la interacción de los componentes.

Con el estudio realizado se pudo evidenciar que es necesario integrar esquemas para reducción de perturbaciones al modelo neuronal ANFIS y que no siempre puede asegurarse la fácil implementación de modelos neuro-difusos debido a la necesidad de integrar técnicas híbridas adaptativas combinadas con modelos Neuro-difusos. Por lo tanto, se plantea como trabajos futuros la implementación de modelos con otras técnicas que permitan facilitar la implementación de los mismos, pero que garanticen eliminar en un mejor porcentaje los rizados indeseables y logren mantener el desempeño logrado en este trabajo como el sobreponer la información incompleta sin afectar la operación del controlador en relación con la estabilidad del sistema y alto desempeño en la identificación.

REFERENCIAS

- Abburi, N.R., & Dixit, U.S. (2006). A knowledge-based system for the prediction of surface roughness in turning process. *Robotics and Computer-Integrated Manufacturing*, 22(4), 363-372.
- Akpan, V.A., & Hassapis, G.D. (2011). Nonlinear model identification and adaptive model predictive control using neural networks. *ISA Transactions*, 50(2), 177-194.
- Allmendinger, E. (1990) *Submersible vehicle systems design*, The society of naval architects and marine engineers, Jersey City (NJ).
- Åström, K.J. (1983). Theory and applications of adaptive control-A survey. *Automatica*, 19(5), 471-486.
- Åström, K.J., & Wittenmark, B. (1973). On self-tuning regulators. *Automatica*, 9(2), 185-199.
- Azadeh, A., Asadzadeh, S.M., Saberi, M., Nadimi, V., Tajvidi, A., & Sheikalishahi, M. (2011). A Neuro-fuzzy-stochastic frontier analysis approach for long-term natural gas consumption forecasting and behavior analysis: The cases of Bahrain, Saudi Arabia, Syria, and UAE. *Applied Energy*, 88(11), 3850-3859.
- Azisa, F.A., Arasa, M.S.M., Rashida, M.Z.A., Othmanb, M.N. & Abdullahc, S.S. (2012). Problem Identification for Underwater Remotely Operated Vehicle (ROV): A Case Study. *Procedia Engineering*, 41, 554-560.
- Balasubramaniam, P., & Nagamani., G. (2012). Global robust passivity analysis for stochastic fuzzy interval neural networks with time-varying delays. *Expert Systems with Applications*, 39(1), 732-742.
- Baruch, I.S., Beltran-Lopez, R., Olivares-Guzman, J.L., & Flores, J.M. (2008). A fuzzy-neural multi-model for nonlinear systems identification and control. *Fuzzy Sets and Systems*, 159(20), 2650-2667.
- Bohm, H. & Jensen, V. (2004). Introduction to underwater technology and vehicle design. Marine Advanced Technology Education: Monterrey Peninsula College.
- Blythe, S., Mao, X., & Liao, X. (2001). Stability of stochastic delay neural networks. *Journal of the Franklin Institute*, 338, 481-495.
- Brito, D.S., Aguiar, E., Lucena, F., Freire, R.C.S., Yasuda, Y. & Barros, A.K. (2009). Influence of low frequency noise in adaptive estimation using the LMS algorithm. *Signal Processing*, 89(5), 933-940.
- Cao, Z., Mu, Q., Hu, L., Liu, Y., & Xuan, L. (2010). Improve the loop frequency of liquid crystal adaptive optics by concurrent control technique. *Optics Communications*, 283(6), 946-950.

- Carravetta, F., & Mavelli, G. (2007). Suboptimal stochastic linear feedback control of linear systems with state and control-dependent noise: The incomplete information case. *Automatica*, 43(5), 751-757.
- Castellanos, O.F. (2007). *Gestión tecnológica: de un enfoque tradicional a la inteligencia*. Bogotá, Colombia: Publicaciones Universidad Nacional de Colombia.
- Castillo, O., & Melin, P. (2004). Adaptive Noise Cancellation using Type-2 Fuzzy Logic and Neural Networks. *Fuzzy-IEEE international conference (10.1109/FUZZY.2004.1375563)*, 2, 1093-1098.
- Chandrasekhar, S. (1954). Stochastic Problems in Physics and Astronomy. *Nelson Wax*, 15(1), 1-89.
- Chang, C-Y., Shyu, K-K. (2003). Active noise cancellation with a fuzzy adaptive filtered-X algorithm. *IEE Proc-Circuits Devices System*, 150(5), 416-422.
- Chaves, P., & Kojiri, T. (2007). Deriving reservoir operational strategies considering water quantity and quality objectives by stochastic fuzzy neural networks. *Advances in Water Resources*, 30(5), 1329-1341.
- Che, J., Wang, J., & Wang, G. (2012). An adaptive fuzzy combination model based on self-organizing map and support vector regression for electric load forecasting. *Energy*, 37(1), 657-664.
- Chen, C-S., & Chen, H-H. (2009). Robust adaptive neural-fuzzy-network control for the synchronization of uncertain chaotic systems. *Nonlinear Analysis: Real World Applications*, 10(3), 1466-1479.
- Chen, Z., Zhao, L., & Lee, K. (2010). Environmental risk assessment of offshore produced water discharges using a hybrid fuzzy-stochastic modeling approach. *Environmental Modelling & Software*, 25(6), 782-792.
- Chin, C., Lau, M., Low, E., & Seet, G. (2006). Software modelling and simulation of a remotely operated vehicle (ROV). *International Journal Simulation Modelling*, 3, 114-125.
- Da Silva, I. (2006). *Aspectos de Sincronización de un sistema caótico*. (tesis doctoral). Universitat de Les Illes Balears.
- Del-Hoyo, R., Martin-del-Brío, B., Medrano, N., & Fernández-Navajas, J. (2009). Computational intelligence tools for next generation quality of service management. *Neurocomputing*, 72(16-18), 3631-3639.
- Doob, J.L. (1942). The Brownian Movement and Stochastic Equations. *Nelson Wax*, 43(2), 351.
- Dorato, P. (1987). A historical review of robust control. *IEEE Control Systems Magazine*, 7(2), 44-47.

- Ensari, T., & Arik, S. (2010). New results for robust stability of dynamical neural networks with discrete time delays. *Expert Systems with Applications*, 37(8), 5925-5930.
- Estiballo, J., & Zamora, M. (2002). Un análisis sectorial-regional de la productividad del trabajo en España. *Cuadernos de Estudios Empresariales*, 12, 27-48.
- Fossen, T.I., & sagatun S.I. (1991). Adaptive control of nonlinear underwater robotic systems. *Modeling identification and control*, 12(2), 95-105.
- Fossen, T.I. (1999). *Guidance and Control of Ocean Vehicles*. Norway, Australia: Jacaranda Wiley Ltda.
- Fossen, T.I. (1994). *Guidance and Control of Ocean Vehicles*. New York, USA: John Wiley & Sons.
- Fu, J., Zhang, H., Ma, T., & Zhang, Q. (2010). On passivity analysis for stochastic neural networks with interval time-varying delay. *Neurocomputing*, 73(4-6), 795-801.
- Gao, W-H., & Deng, F-Q. (2009). Parameter-dependent robust stability for nonlinear distributed delay stochastic systems with polytopic-type uncertainties. *Proceedings of the Eighth International Conference on Machine Learning and Cybernetics*, 6, 3684-3689.
- Gao, Y., & Er, M.J. (2003). Online adaptive fuzzy neural identification and control of a class of MIMO nonlinear systems. *IEEE Transactions on Fuzzy Systems*, 11(4), 462-477.
- Gillespie, D. (1996). Exact numerical simulation of the Ornstein Ouhlembeck process and its integral. *Physical Review*, 54(2), 46-54.
- Gong, Z-W. (2008). Least-square method to priority of the fuzzy preference relations with incomplete information. *International Journal of Approximate Reasoning*, 47(2), 258-264.
- Gu, H., Zhang, T., & Shen, Q. (2006). Decentralized model reference adaptive sliding mode control based on fuzzy model. *Journal of Systems Engineering and Electronics*, 17(1), 182-186.
- Gumus, A.T., & Guneri, A.F. (2009). A multi-echelon inventory management framework for stochastic and fuzzy supply chains. *Expert Systems with Applications*, 36(3), 5565-5575.
- Han, H., Su, C-Y., & Stepanenko, Y. (2001). Adaptive control of a class of nonlinear systems with nonlinearly parameterized fuzzy approximators. *IEEE Transactions on Fuzzy Systems*, 9(2), 315-323.
- Hayati, H., Rezaei, A. & Naderi, A. (2010). Modeling and simulation of combinational CMOS logic circuits by ANFIS. *Microelectronics Journal*, 41, 381-387.
- Hoskinson, R., Van den Doel, K. & Fels, S. (2003). Real-time adaptive control of modal synthesis. *Proceedings of the 2003 Conference on New Interfaces for Musical Expression (NIME'03)*, 99-103.

- Hossain, A., Choudhury, Z.A., & Suyut, S. (1996). Statistical Process Control of an Industrial Process in Real Time. *IEEE Transactions on Industry Applications*, 32(2), 243-249.
- Hsieh, K-L., Tong, L-I., & Wang, M-C. (2007). The application of control chart for defects and defect clustering in IC manufacturing based on fuzzy theory. *Expert Systems with Applications*, 32(3), 765-776.
- Hsu, C-F. (2007). Self-organizing adaptive fuzzy neural control for a class of nonlinear systems. *IEEE Transactions on Neural Networks*, 18(4), 1232-1241.
- Hu, Y., & Nualart, D. (2010). Parameter estimation for fractional Ornstein-Uhlenbeck processes, *Statistics & Probability Letters*, 80(11-12), 1030-1038.
- Huang, T.W. (2006). Exponential stability of fuzzy cellular neural networks with distributed delays. *Physics Letters A*, 351, 48-52.
- Huang, H., & Cao, J. (2007). Exponential stability analysis of uncertain stochastic neural networks with multiple delays. *Nonlinear Analysis: Real World Applications*, 8(2), 646-653.
- Jang, J-S. R. (1992). *Neurofuzzy Modeling: Architecture, Analyses and Applications. Tesis de Doctorado*. CA, Estados Unidos: University of California, Berkeley.
- Jang, J-S. R. (1993). ANFIS: Adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man, and Cybernetics*, 23, 665-685.
- Javadi-Moghaddam, J. & Bagheri, A. (2010). An adaptive neuro-fuzzy sliding mode based genetic algorithm control system for under water remotely operated vehicle. *Expert Systems with Applications*, 37(1), 647-660.
- Kalman, R.E. (1958). Design of a self-optimizing control system. *Transactions of the American Society of Mechanical Engineers*, 80, 468-478.
- Karhunen, K. (1952). Métodos lineales en el Cálculo de Probabilidades. *Trabajos de Estadística and Trabajos de Estadística y de Investigación Operativa*, 3(1-2), 59-137.
- Khintchine, A. (1934). Korrelationstheorie der stationären stochastischen Prozesse. *Mathematische Annalen*, 109(1), 604-615.
- Landín, M., Rowe, R.C., & York, P. (2009). Advantages of neurofuzzy logic against conventional experimental design and statistical analysis in studying and developing direct compression formulations. *European Journal of Pharmaceutical Sciences*, 38(4), 325-331.
- Leu, Y-G., Wang, W-Y., & Lee, T-T. (1999). Robust adaptive fuzzy-neural controllers for uncertain nonlinear systems. *IEEE Transactions on Robotics and Automation*, 15(5), 805-817.
- Leu, Y-G., Wang, W-Y., & Li, I-H. (2009). RGA-based on line tuning of BMF fuzzy-neural networks for adaptive control of uncertain nonlinear systems. *Neurocomputing*, 72(10-12), 2636-2642.

- Lévy, P. (1965). *Processus stochastiques et mouvement brownien*. 2^a Ed. Paris: Gauthier-Villars.
- Li, H., Chen, B., Lin, C., & Zhou, Q. (2009). Mean square exponential stability of stochastic fuzzy Hopfield neural networks with discrete and distributed time-varying delays. *Neurocomputing*, 72(7-9), 2017-2023.
- Li, H-X., & Liu, Z. (2009) A Probabilistic Fuzzy Logic System: learning in the stochastic environment with incomplete dynamics. *IEEE International Conference on Systems, Man and Cybernetics (SMC2009)*, 383-388.
- Liang, J., Wang, Z., & Liu, X. (2010). Robust passivity and passification of stochastic fuzzy time-delay systems. *Information Sciences*, 180, 1725-1737.
- Lim, Y., Venugopal, R., & Ulsoy, A.G. (2012). Auto-tuning and adaptive control of sheet metal forming. *Control Engineering Practice*, 20(2), 156-164.
- Lin, W., & Byrnes, C.I. (1995). Passivity and absolute stabilization of a class of discrete-time nonlinear systems. *Automatica*, 31(2), 263-267.
- Liu, B., & Shi, P. (2009). Delay-range-dependent stability for fuzzy BAM neural networks with time-varying delays. *Physics Letters A*, 373(21), 1830-1838.
- Liu, P., & Li, H. (2005). Approximation of stochastic processes by T-S fuzzy systems. *Fuzzy Sets and Systems*, 155(2), 215-235.
- Liu, X.W. (2007). Passivity analysis of uncertain fuzzy delayed systems. *Chaos, Solitons and Fractals*, 34, 833-838.
- Liu, Z., Li, H-X., & Zhang, Y. (2008). A Probabilistic Wavelet System for Stochastic and Incomplete Data-Based Modeling. *IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics*, 38(2), 310-319.
- Li, H., & Liu, Z. (2008). A Probabilistic Neural-Fuzzy Learning System for Stochastic Modeling. *IEEE Transactions on Fuzzy Systems*, 16(4), 898-908.
- Loria, A., & Zavala-Rio, A. (2007). Adaptive tracking control of chaotic systems with applications to synchronization. *IEEE Transactions on Circuits and Systems I Regular Papers*, 54(9), 2019-2029.
- Lou, X.Y., & Cui, B.T. (2007). Robust asymptotic stability of uncertain fuzzy BAM neural networks with time-varying delays. *Fuzzy Sets and Systems*, 158, 2746-2756.
- Marusak, P.M. (2009). Advantages of an easy to design fuzzy predictive algorithm in control systems of nonlinear chemical reactors. *Applied Soft Computing*, 9(3), 1111-1125.
- Meadows, G. & Meadows, L. (2003). *Ship design and construction*. 1^a. Ed. Jersey City (NJ): The society of naval architects and marine engineers.

- Meharrar, A., Tioursi, M., Hatti, M., & Boudghène-Stambouli, A. (2011). A variable speed wind generator maximum power tracking based on adaptative neuro-fuzzy inference system. *Expert Systems with Applications*, 38(6), 7659-7664.
- Mejía Alvarez, A. (2009). *Caso de control neuronal adaptable para sistemas multivariados*. (Tesis). Medellín. Universidad Nacional de Colombia.
- Mitter, S.K. (1996). Filtering and stochastic control: A historical perspective. *IEEE Control Systems*, 16(3), 67-76.
- Naderloo, L., Alimardani, R., Omid, M., Sarmadian, F., Javadikia, P., Torabi, M.Y., & Alimardani, F. (2012). Application of ANFIS to predict crop yield based on different energy inputs. *Measurement*, 45(6), 1406-1413.
- Navia, A., & Díaz, R. (2011). Adaptive sigmoidal plant identification using reduced sensitivity recursive least squares. *Signal Processing*, 91(4), 1066-1070.
- Narendra, K. S., & Zhuo, H. (2010). Location of models in multiple-model based adaptive control for improved performance. *In Proc. American Control Conference (ACC'10)*, 117-122.
- Newman, J. (1997). *Marine Hydrodynamics*. 8^a Ed. U.S.A, Cambridge, MA, MIT Press.
- Novák, V. (2012). Reasoning about mathematical fuzzy logic and its future. *Fuzzy Sets and Systems*, 192, 25-44.
- Ogata, K. (2010). *Ingeniería de Control Moderna*. 5^a Ed. Madrid, España: Pearson Educación, Prentice Hall.
- Ogata, K. (1996). *Ingeniería de Control en Tiempo Discreto*. 2^a Ed. Madrid, España: Pearson Educación, Prentice Hall.
- Park, O. H., & Seok, M. G. (2007). Selection of appropriate model to predict plume dispersion in coastal areas. *Atmospheric Environment*, 41(29), 6095–6101.
- Pehlivanoglu, Y.V., & Baysal, O. (2010). Vibrational genetic algorithm enhanced with fuzzy logic and neural networks. *Aerospace Science and Technology*, 14(1), 56-64.
- Raffo, L., & Mejía, P. (2006). Aplicaciones computacionales de las ecuaciones diferencial estocásticas. *Industrial Data*, 9(1), 64-75.
- Ridao, P., Batlle, J., and Carreras, M. (2001). Dynamics Model of an Underwater Robotic Vehicle, Technical Report, IIA 01-05-RR, Universitat de Girona, Spain.
- Rodríguez-Gamboa, J.C., Albarracín-Estrada, E.S., & Delgado-Trejos, E. (2011). *Quality Control Through Electronic Nose System*. In: *Modern Approaches to Quality Control by Eldin*, A.B. (Ed.), InTech, 505-522, Rijeka, Croatia.
- Salehi, S. & Shahrokhi, M. (2009). Adaptive fuzzy backstepping approach for temperature control of continuous stirred tank reactors. *Fuzzy Sets and Systems*, 160(12), 1804-1818.

- Sánchez, E., & Alanis G., A. (2006). *Redes neuronales: conceptos fundamentales y aplicaciones a control automático*. 1ª Ed. Pearson Educación, Prentice Hall.
- Sánchez, S., & Giraldo, E. (2008). Speed control of induction motor using fuzzy recursive least squares technique. *Revista Tecnológicas*, 21, 99-111.
- Sanz, J., Fernández, A., Bustince, H., & Herrera, F. (2011). A genetic tuning to improve the performance of Fuzzy Rule-Based Classification Systems with Interval-Valued Fuzzy Sets: Degree of ignorance and lateral position. *International Journal of Approximate Reasoning*, 52(6), 751-766.
- Shao, H. (2010). Novel delay-dependent stability results for neural networks with time-varying delays. *Circuits, Systems, and Signal Processing*, 29, 637-647.
- Sheng, L., Gao, M., & Yang, H. (2009). Delay-dependent robust stability for uncertain stochastic fuzzy Hopfield neural networks with time-varying delays. *Fuzzy Sets and Systems*, 160, 3503-3517.
- Shibata, T. (2008). The impacts of uncertainties in a real options model under incomplete information. *European Journal of Operational Research*, 187(3), 1368-1379.
- Shim, H., Jun, B-H., Mooklee, P., Baek, H. & Lee, J. (2010). Workspace control system of underwater tele-operated manipulators on an ROV. *Ocean Engineering*, 37, 1036-1047.
- Shu, Z., & Lam, J. (2008). Global exponential estimates of stochastic interval neural networks with discrete and distributed delays. *Neurocomputing*, 71(13-15), 2950-2963.
- Silveira, A.S., Rodríguez, J.E.N., & Coelho, A.A.R. (2012). Robust design of a 2-DOF GMV controller: A direct self-tuning and fuzzy scheduling approach. *ISA Transactions*, 51(1), 13-21.
- Souza, F.O., & Palhares, R.M. (2010). Interval time-varying delay stability for neural networks. *Neurocomputing*, 73, 2789-2792.
- Stella, M., Begusic, D., & Russo, M. (2006). Adaptive Noise Cancellation Based on Neural Network. *Software in Telecommunications and Computer Networks*, (10.1109/SOFTCOM.2006.329765). *International conference on IEEE*, 306-309.
- Su, W., & Chen, Y. (2009). Global robust exponential stability analysis for stochastic interval neural networks with time-varying delays. *Communications in Nonlinear Science and Numerical Simulation*, 14, 2293-2300.
- Stein, G., & Saridis, G.N. (1969). A parameter-adaptive control technique. *Automatica*, 5(6), 731-739.
- Syed-Ali, M., & Balasubramaniam, P. (2009). Exponential stability of uncertain stochastic fuzzy BAM neural networks with time-varying delays. *Neurocomputing*, 72(4-6), 1347-1354.
- Takagi, T., & Sugeno, M. (1985). Fuzzy identification of systems and its application to modeling and control. *IEEE Transactions on Systems, Man, and Cybernetics*, 15, 116-132.

- Tan, K.K., Lee, T.H., & Jiang, X. (2000). Robust on-line relay automatic tuning of PID control systems. *ISA Transactions*, 39(2), 219-232.
- Tian, J., & Zhou, X. (2010). Improved asymptotic stability criteria for neural networks with interval time-varying delay. *Expert Systems with Applications*, 37, 7251-7525.
- Toola, A. (1993). The safety of process automation. *Automatica*, 29(2), 541-548.
- Ushida, S. (2011). Control performance improvements due to fluctuations in dynamics of stochastic control systems. *50th IEEE Conference on Decision and Control and European Control Conference (CDC-ECC'2011)*, 1430-1436.
- Valencia C., R. (2008). Fluid and structural simulation of a ROV. Medellín: Universidad Eafit.
- Velásquez, J. (2004). Cómo justificar proyectos de automatización. *Industrial data*, 7(1), 7-11.
- Villada, F., García, E., & Molina, J.D. (2011). Electricity Price Forecasting using Neuro-Fuzzy Networks. *Información Tecnológica*, 22(6), 111-120.
- Wang, S., Hou, L., Dong, L. & Xiao, H. (2011). Adaptive fuzzy sliding mode control of uncertain nonlinear SISO systems. *Procedia Engineering*, 24, 33-37.
- Wang, W., & Tang, B. (1999). A fuzzy adaptive method for intelligent control. *Expert Systems with Applications*, 16(1), 43-48.
- Wang, Y., Song, J. & Zhang, B. (2011). Fuzzy Sliding-Mode Variable Structure Control for Fan Filter Units' Motor Speed Regulation System. *Procedia Engineering*, 15, 969-973.
- Wu, B-F., Ma, L-S., Perng, J-W., & Chin, H-I. (2008). Absolute stability analysis in uncertain static fuzzy control systems with the parametric robust Popov criterion. *IEEE International Conference on Fuzzy Systems (FUZZ-IEEE 2008)*, 1(6), 1325-1330.
- Xu, L., Wang, J., & Chen, Q. (2012). Kalman filtering state of charge estimation for battery management system based on a stochastic fuzzy neural network battery model. *Energy Conversion and Management*, 53(1), 33-39.
- Yang, H., & Sheng, L. (2009). Robust stability of uncertain stochastic fuzzy cellular neural networks. *Neurocomputing*, 73(1-3), 133-138.
- Yang, Q., Xue, Y., Yang, S.X., & Yang, W. (2012). An auto-tuning method for dominant-pole placement using implicit model reference adaptive control technique. *Journal of Process Control*, 22(3), 519-526.
- Yuh, J. (1990). Modeling and Control of Underwater Robotic Vehicles. *IEEE Transactions on system, man, and cybernetics*, 20(6), 1475-1483.
- Zhang, A. (2008). Robust Reliable Fuzzy Control for Uncertain Markovian Jump Singular Systems. *Fifth International Conference on Fuzzy Systems and Knowledge Discovery (FSKD'08)*, 1, 406-410.

- Zhang, X., Lu, G., & Zheng, Y. (2008). Stabilization of Networked Stochastic Time-Delay Fuzzy Systems with Data Dropout. *IEEE Transactions on Fuzzy System*, 16(3), 798-807.
- Zhou, J., & Liu, B. (2003). New stochastic models for capacitated location-allocation problem. *Computers & Industrial Engineering*, 45(1), 111-125.
- Zúñiga, A., & Jordán, C. (2005). Pronóstico de caudales medios mensuales empleando Sistemas NeuroFuzzy. *Revista Tecnológica ESPOI*, 18(1), 17-23.

APÉNDICE A

Especificaciones técnicas del ROV

A.1 Selección de la propela para el sistema de propulsión

El rendimiento de una propela comercial se basa en las especificaciones de marca, material, diámetro, inclinación, rotación y número de cuchillas. Las siguientes son las características de las propelas usadas para el ROV usado como modelo de este trabajo:

Marca: Modelos Harbor

Material: Bronce

Diámetro: 0,0889 m

Inclinación: 0,1016 m

Rotación: derecho

Número de cuchillas: 4

En la Tabla A.1. Se puede observar el plano frontal de distribución de la presión en el lugar de acción de la hélice.

Variable	Valor
Empuje	10.5813 N
Torque	0.162974 Nm
Poder	27.3796 W
J(proporción de avance)	0.420696
KQ(Torque)	0.0400913
KT(Empuje)	0.231406
Eficiencia	0.386468

Tabla A.1. Plano frontal de distribución de la presión en el lugar de acción de la hélice.

Fuente: Tomada de (Valencia, 2008).

Asimismo en la Tabla A.2. Se especifica el momento y masa como valores de referencia.

Variable	Valor
Empuje	10.3061 N
Torque	0.159568 Nm
Poder	26.8074 W
J (proporción de avance)	0.420696
KQ(Torque)	0.0392534
KT(Empuje)	0.225387
Eficiencia	0.384451

Tabla A.2. Momento y masa como valores de referencia.

Fuente: Tomada de (Valencia, 2008).

A.2 Características generales del ROV

Los lugares de operación de ROV de este proyecto son los puertos comerciales más importantes de Colombia: Cartagena, Barranquilla, Santa Marta y Buenaventura. Estas ubicaciones sirven para establecer parámetros como la profundidad, la densidad, la salinidad, la temperatura y velocidad de la corriente. La densidad del agua varía, dependiendo de la profundidad, temperatura y salinidad. En términos de la temperatura, en torno a 4° C, agua a una densidad máxima. En cuanto a la salinidad, la densidad disminuye cuando aumenta la salinidad. En términos de profundidad, la densidad del agua de mar varía de 1012 kg/m³ a la superficie a 1070 kg/m³ a 1000m de profundidad (Meadows, G. & Meadows, L, 2003). Además, la temperatura varía dependiendo de la profundidad: entre 0 y 200m de profundidad, la temperatura es muy similar a la superficie y se aproxima a 0° C con profundidad a 4000m. La profundidad de operación de ROV se define a 100m, que corresponde a una presión hidrostática de 1,00 MPa (145,5 psi), si bien, uno de los objetivos del vehículo es la inspección en puertos colombianos.

El ROV Fue desarrollado en 1998 como un vehículo de funcionamiento dual: autónomo y operado remotamente. Fue diseñado para operar a una profundidad máxima de 100 m, para desplazarse a una velocidad máxima de 1 nudo (0.5 m/s) y moverse con cuatro grados de libertad (desplazamiento longitudinal, rotación alrededor del eje vertical, desplazamiento transversal y desplazamiento vertical), con un sistema de adquisición de imágenes, entre otros. Las consideraciones y variables de diseño se desprenden de las características del ambiente de trabajo al cual estará sometido el vehículo. Éstas determinan aspectos como la presión de trabajo, la velocidad de operación, las condiciones de flotabilidad, las condiciones ambientales, entre otros. En esta sección se describen las más relevantes.

A.2.1 Consideraciones hidrostáticas e hidrodinámicas.

Masa y dimensiones del vehículo. En cuanto a la masa y dimensiones del vehículo, el peso no supera 100 kg y las dimensiones son pequeñas ya que el ROV es introducido en una caja cúbica con 1 m de lado.

Cargas de interés. Las cargas de interés que influyen en el comportamiento de un vehículo sumergible son: peso, desplazamiento (peso del volumen desalojado), arrastre y sustentación, propulsión, fuerzas de contacto, cargas inerciales.

Equilibrio estático. La flotabilidad se define como la diferencia algebraica entre el desplazamiento y el peso. Se dice que existe flotabilidad positiva cuando el desplazamiento es mayor que el peso, negativa cuando el desplazamiento es menor que el peso y neutra cuando el desplazamiento y el peso son equivalentes.

Estabilidad estática. El vehículo tiene una condición de equilibrio estable, recupera de forma natural su inclinación ante la incidencia de cargas perturbadoras. Ésta se asegura logrando que el centro de volumen esté por encima del centro de masa.

Estabilidad dinámica. El vehículo cuenta con la energía suficiente para que tienda naturalmente a su posición de equilibrio estable. Ésta depende de la ubicación relativa del centro de masa y del centro de volumen, la estabilidad mejora con el aumento de esta distancia.

Arrastre y propulsión. La potencia de los propulsores permite vencer las fuerzas de arrastre hidrodinámico y éste pueda moverse según los requerimientos de velocidad y aceleración.

Movilidad. El vehículo está en la capacidad de trasladarse en tres direcciones no paralelas: avance longitudinal (*surge*), avance lateral (*sway*), movimiento vertical (*heave*) y que sea capaz de cambiar su orientación sobre el plano horizontal rotando alrededor del eje vertical (*yaw*).

Velocidad de operación. La velocidad de operación del vehículo está sujeta a la velocidad de las corrientes a las cuales estará sometido en el sitio de operación (puertos), con el fin de garantizar que el sumergible esté en la capacidad de mantenerse estático sin importar la incidencia directa de éstas. Según las condiciones de velocidad de corrientes en puerto, se establece que la velocidad máxima de operación debe ser de 1.5 m/s (3 nudos aproximadamente).

A.2.2 Instrumentación, control, potencia y comunicaciones

Para cumplir con las tareas de inspección y permitir una mayor facilidad en la operación del vehículo, se cuenta con los dispositivos de hardware: Control. Para el control se requiere del uso de un computador a bordo, que recibe la referencia del operador en superficie, que esté en la capacidad de tomar información de los instrumentos de medición, procesarla y entregar señales de control a los dispositivos actuadores (propulsores), con el fin de desarrollar labores de estabilización de bajo nivel (capacidad de responder controladamente a las indicaciones del operador).

Propulsores. Se utiliza una configuración de cuatro propulsores. Dos de ellos permiten el avance longitudinal y rotación alrededor del eje vertical, uno para avance lateral y uno para avance vertical. Cada propulsor cuenta con un motor DC sin escobillas y sellos mecánicos para el eje de la propela.

Instrumentación. Para la toma de información se requiere del uso de los siguientes instrumentos: unidad inercial para la medición de aceleraciones lineales y velocidades

angulares, compás digital para medir la orientación, profundímetro para determinar la posición vertical, termómetro.

Potencia. Para la alimentación del vehículo se usa corriente alterna a 110 V. A bordo se usa una fuente de voltaje para la instrumentación y otra para los propulsores. También se tienen en cuenta los amplificadores (*drivers*) que permiten hacer un enlace entre las señales de control y la alimentación de potencia que requieren los actuadores.

Comunicación. Para la comunicación se hace uso de fibra óptica y de dispositivos convertidores que permiten la conexión con el procesador a bordo y demás dispositivos que se comuniquen directamente con la estación en superficie.

A.2.3 Especificaciones del vehículo

CARACTERÍSTICA	VALOR
Categoría	Observación
Ambiente de operación	Agua salada (puerto)
Densidad agua salada	1024 kg/m ³
Profundidad de operación	100 m (1.00 Mpa)
Profundidad de diseño	165 m (1.66 Mpa)
Temperatura de operación	0 – 40 °C
Movilidad	Cuatro grados de libertad: <i>surge, sway, heave, yaw</i>
Velocidad máxima	1.5 m/s (3 nudos)
Flotabilidad	Neutra – positiva (margen de 2.5 N)
Peso máximo	100 kg
Sistema de comunicación y alimentación	Cable umbilical con fibra óptica
Instrumentos para navegación	Unidad inercial, profundímetro y compás digital.
Instrumentos de análisis	Termómetro
Sistemas auxiliares	Sistema de iluminación, sistemas auxiliares de comunicación (convertidores)
Características cualitativas	Robustez, confiabilidad, apariencia, facilidad en el transporte, mantenibilidad, funcionalidad.

Las profundidades (en m): de acuerdo a los informes de las Sociedades Regionales de Puerto Colombia son los siguientes:

Barranquilla 12

Buenaventura 13.7

Cartagena 13.7

Santa Marta 18.3

La velocidad de funcionamiento del vehículo depende de la velocidad de las corrientes en los puertos. La velocidad de funcionamiento es de aproximadamente 1,5 m / s (3 nudos). En el movimiento de un objeto sólido, el vehículo sumergible en este caso. La velocidad del flujo del agua es relativamente baja con respecto a lo estudiado en la aeronáutica, donde el intervalo es de aproximadamente de cero a 96,48 kmh (Bohm & Jensen, 2004). En el diseño del ROV, los efectos de la resistencia por fricción son insignificantes en comparación con el arrastre por presión.

La viscosidad cinemática es una función de la temperatura, la presión y salinidad del agua. La Tabla A.3. Muestra esta variación entre temperatura, densidad y viscosidad cinemática:

Temperatura [°K]	Densidad [kg/m ³]	Viscosidad cinemática [m ² / s]
273.15	31.9520	-
274.26	31.9504	-
275.37	31.9472	-
276.48	31.9440	-
277.59	31.9408	-
278.71	31.9360	0.1539
279.82	31.9312	0.1490
280.93	31.9264	0.1443
282.04	31.9216	0.1398
283.15	31.9152	0.1356
284.26	31.9104	0.1316
285.37	31.9040	0.1278
286.48	31.8960	0.1140
287.59	31.8896	0.1207
288.71	31.8815	0.1174
289.82	31.8735	0.1143
290.93	31.8655	0.1113
292.04	31.8575	0.1084
293.15	31.8479	0.1056
294.26	31.8383	0.1030
295.37	31.8287	0.1005
296.48	31.8191	0.0980
297.59	31.8095	0.0957
298.71	31.7982	0.0935
299.82	31.7870	0.0913

Tabla A.3. Viscosidad Cinemática vs temperatura y densidad.

Fuente: Tomada de (Allmendinger, 1990).

A.3 Simulación de las fuerzas de arrastre del ROV

Las velocidades del fluido fueron seleccionados de acuerdo a la velocidad máxima esperada a la que el vehículo se mueve, 1,5 m/s (aproximadamente 3 nudos), con respecto a las corrientes marinas y el movimiento hacia adelante (*surge*). Para el movimiento de rotación (*yaw*), el marco de referencia es situado en el centro volumétrico del vehículo, se impone una condición de rotación con velocidades angulares en un rango entre 0,3 y 3 rad/s.

En la tabla A.4. Muestra la simulación de las fuerzas de arrastre del ROV y en la Tabla A.5. Los torques para el movimiento en *Yaw*.

Escenario	Velocidad de flujo	Dirección	Plano simétrico
1	0,5	X	no
2	1	X	no
3	1,5	X	no
4	2	X	no
5	-2	Y	yz
6	-1,5	Y	yz
7	-1	Y	yz
8	-0,5	Y	yz
9	0,5	Y	yz
10	1	Y	yz
11	1,5	Y	yz
12	2	Y	yz
13	-2	Z	yz
14	-1,5	Z	yz
15	-1	Z	yz
16	-0,5	Z	yz
17	0,5	Z	yz
18	1	Z	yz
19	1,5	Z	yz
20	2	Z	yz

Tabla A.4. Simulación de las fuerzas de arrastre del ROV, condiciones de dominio.

Fuente: Tomada de (Valencia, 2008).

Escenario Angular	Velocidad (rad/s)	Torque (N-m)
21	0.3	-0.09887
22	0.6	-0.38564
23	0.9	-0.85723
24	1.0	-1.27185
25	1.2	-1.40927
26	1.5	-2.35105
27	1.8	-3.37002
28	2.0	-4.18020
29	2.5	-6.50028
30	3.0	-9.46234

Tabla A.5. Torques para el movimiento *Yaw*.

Fuente: Tomada de (Valencia, 2008).