

APENDICE A1

ALGORITMO DE RETROPROPAGACION DE ERROR

Enseguida se muestra el listado de instrucciones que componen el algoritmo de retropropagación de error, adecuado para ser utilizado en el simulador MATLAB para WINDOWS, provisto de herramientas de redes neuronales (Neural Network Toolbox).

```
% Algoritmo de retropropagación de error en una red de una capa interna de S1
% elementos. La capa de salida tiene S2 elementos.
clf reset

% PE y PEP son matrices que contienen los patrones de entrada, con dimensiones
% [i,j], i= Número de patrones, j= Número de variables de entrada.
% Se transponen para manejo interno del algoritmo en MATLAB
P = PE'; % Patrones de entrenamiento
P1= PEP'; % Patrones de prueba

% PS y PSP son matrices que contienen los patrones de salida, con dimensiones
% [i,j], i = Número de patrones, j = Número de variables de salida.
T = PS'; % Patrones de entrenamiento
T1= PSP'; % Patrones de salida

% SE DEFINE LA ARQUITECTURA DE LA RED
% R - Número de variables de entrada = Número de elementos en primera capa.
% Q - Número de patrones de entrenamiento.
% S2- Número de variables de salida = Número de elementos en última capa.
% S1- Número de elementos en capa interna
% S1 = 10; % Se da este parámetro externamente
[R,Q] = size(P); [S2,Q] = size(T);

% Se inicializan matrices y vectores de ponderación
[W10,B10] = rands(S1,R);
[W20,B20] = rands(S2,S1);
```

% ENTRENAMIENTO DE LA RED

% Parametros de entrenamiento

```

disp_freq = 10;           % Frecuencia para desplegar resultados
max_epoch = 500;         % Número de iteraciones máximo
err_goal = 0.002;        % Error a alcanzar
lr = 0.0010;             % Paso de aprendizaje inicial
lr_inc = 1.05;           % Incremento del paso
lr_dec = 0.70;           % Decremento del paso
err_ratio = 1.04;        % Tolerancia para activar algoritmo de paso adaptivo

```

% Se almacenan matrices y vectores de ponderación iniciales

```

W1 = W10; B1 = B10;
W2 = W20; B2 = B20;

```

% Se inicializa variable para contar número de operaciones durante el entrenamiento

```
flops(0);
```

% ETAPA PROGRESIVA INICIAL

```

A1 = logsig(W1*P,B1);    % Salida de la capa interna
A2 = logsig(W2*A1,B2);   % Salida de segunda capa
E = T-A2;                % Magnitud de error
SSE = sumsqr(E);         % Suma cuadrática de error de entrenamiento

```

```

EP = T1-logsig(W2*logsig(W1*P1,B1),B2); % Se evalúa error de prueba
SSP = sumsqr(EP);        % Suma cuadrática de error de prueba

```

% Se almacenan error de entrenamiento y prueba iniciales

```

ERR = [SSE; lr];
errorp = [SSP];

```

```

% PROCESO ITERATIVO
for epoch=1:max_epoch

% VERIFICACION DE TOLERANCIAS
if SSE < err_goal, epoch=epoch-1; break, end
if epoch > 10,
    if TR(1,epoch) < 1,
        if TR(1,epoch) >= TR(1,epoch-10), epoch=epoch-1; break, end
    end
end
if epoch > 250,
    if errorp(epoch) >= errorp(epoch-10), epoch=epoch-1; break, end
end

% MODIFICACION DE MATRICES DE PONDERACION
D2 = deltalog(A2,E);
D1 = deltalog(A1,D2,W2);
[dW1,dB1] = learnbp(P,D1,lr);
[dW2,dB2] = learnbp(A1,D2,lr);
TW1 = W1 + dW1; TB1 = B1 + dB1;
TW2 = W2 + dW2; TB2 = B2 + dB2;

% ETAPA PROGRESIVA
% Se añade ruido aleatorio con distribucion normal a patrones de entrada
P = PE' + (randn(size(P)) * 0.01);
TA1 = logsig(TW1*P,TB1);
TA2 = logsig(TW2*TA1,TB2);
TE = T-TA2;
TSSE = sumsqr(TE);
% Error de entrenamiento
% Suma cuadrática de error de
% entrenamiento.

```

```

EP = T1-logsig(W2*logsig(W1*P1,B1),B2); % Error de prueba
SSP = sumsqr(EP); % Suma cuadrática de error de prueba

% PASO DE APRENDIZAJE DE LONGITUD ADAPTABLE
if TSSE > SSE*err_ratio
    lr = lr * lr_dec;
else
    if TSSE < SSE
        lr = lr * lr_inc;
    end
    W1='TW1; B1=TB1; W2=TW2; B2=TB2;
    A1=TA1; A2=TA2; E=TE; SSE=TSSE;
end

% Se almacenan errores de entrenamiento y prueba durante proceso iterativo
TR = [TR [SSE; lr]];
errorp = [errorp SSP];
minep = min(errorp); % Mínimo error de prueba

% Se muestran resultados cada (disp_freq) iteraciones
temp = flops;
if (rem(epoch,disp_freq) == 0)
    if ~(strcmp(computer,'PC') | strcmp(computer,'386'))
        fprintf('epoch=%.0f SSE=%g SSP=%g\n\n',epoch,SSE,SSP)
    end
end
flops(temp);
end
% FIN DE PROCESO ITERATIVO

```

```
totalflops = flops;
```

```
% RESUMEN DE RESULTADOS
```

```
%=====
```

```
SSE = sumsq(T-logsig(W2*logsig(W1*P,B1),B2));
```

```
fprintf('\nVALORES FINALES DE LA RED:\n')
```

```
W1
```

```
B1
```

```
W2
```

```
B2
```

```
fprintf('Entrenado durante %.0f iteraciones.\n',epoch)
```

```
fprintf('El entrenamiento tomo %.0f flops.\n',flops);
```

```
fprintf('Promedio de %.0f flops/iteracion.\n',round(totalflops/epoch));
```

```
fprintf('Promedio de %.0f flops/ciclo.\n',round(totalflops/epoch/Q));
```

```
fprintf('Tolerancia de error %g.\n',err_goal);
```

```
fprintf('Error final alcanzado %g.\n',SSE);
```

```
fprintf('La red opera: ');
```

```
if SSE < err_goal
```

```
    disp('Adecuadamente.')
```

```
else
```

```
    disp('Inadecuadamente.')
```

```
end
```

APENDICE A2

TABLAS DESCRIPTIVAS DE CASOS DE ENTRENAMIENTO

TABLA A2.1
CASOS DE FALLA TRIFASICA EN REC-400

CASO Núm.	FALLA	LUGAR	DEM.	U's	CONFIG.	DISP.
2111	3F	REC-400	MAX.	1234	COMP.	REC-FRO
2112	3F	REC-400	MAX.	1204	COMP.	REC-FRO
2113	3F	REC-400	MAX.	0234	COMP.	REC-FRO
2121	3F	REC-400	MAX.	1234	REC-FRO	REC-FRO
2122	3F	REC-400	MAX.	1204	REC-FRO	REC-FRO
2123	3F	REC-400	MAX.	0234	REC-FRO	REC-FRO
2131	3F	REC-400	MAX.	1234	FRO-VDG	REC-FRO
2132	3F	REC-400	MAX.	1204	FRO-VDG	REC-FRO
2133	3F	REC-400	MAX.	0234	FRO-VDG	REC-FRO
2211	3F	REC-400	MIN.	1234	COMP.	REC-FRO
2212	3F	REC-400	MIN.	1204	COMP.	REC-FRO
2213	3F	REC-400	MIN.	0234	COMP.	REC-FRO
2221	3F	REC-400	MIN.	1234	REC-FRO	REC-FRO
2222	3F	REC-400	MIN.	1204	REC-FRO	REC-FRO
2223	3F	REC-400	MIN.	0234	REC-FRO	REC-FRO
2231	3F	REC-400	MIN.	1234	FRO-VDG	REC-FRO
2232	3F	REC-400	MIN.	1204	FRO-VDG	REC-FRO
2233	3F	REC-400	MIN.	0234	FRO-VDG	REC-FRO

En cada caso se corren 25 simulaciones de estabilidad (Ver sección 3.5), con excepción de los casos 2121 y 2131, en que no se encuentra convergencia para la condición de máxima generación, por lo que se efectúan únicamente 24.

TABLA A2.2
CASOS DE FALLA TRIFASICA EN FRO-400

CASO Núm.	FALLA	LUGAR	DEM.	U's	CONFIG.	DISP.
3111	3F	FRO-400	MAX.	1234	COMP.	REC-FRO
3112	3F	FRO-400	MAX.	1204	COMP.	REC-FRO
3113	3F	FRO-400	MAX.	0234	COMP.	REC-FRO
3121	3F	FRO-400	MAX.	1234	REC-FRO	REC-FRO
3122	3F	FRO-400	MAX.	1204	REC-FRO	REC-FRO
3123	3F	FRO-400	MAX.	0234	REC-FRO	REC-FRO
3131	3F	FRO-400	MAX.	1234	FRO-VDG	REC-FRO
3132	3F	FRO-400	MAX.	1204	FRO-VDG	REC-FRO
3133	3F	FRO-400	MAX.	0234	FRO-VDG	REC-FRO
3211	3F	FRO-400	MIN.	1234	COMP.	REC-FRO
3212	3F	FRO-400	MIN.	1204	COMP.	REC-FRO
3213	3F	FRO-400	MIN.	0234	COMP.	REC-FRO
3221	3F	FRO-400	MIN.	1234	REC-FRO	REC-FRO
3222	3F	FRO-400	MIN.	1204	REC-FRO	REC-FRO
3223	3F	FRO-400	MIN.	0234	REC-FRO	REC-FRO
3231	3F	FRO-400	MIN.	1234	FRO-VDG	REC-FRO
3232	3F	FRO-400	MIN.	1204	FRO-VDG	REC-FRO
3233	3F	FRO-400	MIN.	0234	FRO-VDG	REC-FRO

En cada caso se corren 25 simulaciones de estabilidad, con excepción de los casos 3121 y 3131, en que no se encuentra convergencia para la condición de máxima generación, por lo que se efectúan únicamente 24.

TABLA A2.3
CASOS DE FALLA MONOFASICA EN REC-230

CASO Núm.	FALLA	LUGAR	DEM.	U's	CONFIG.	DISP.
4111	1F	REC-230	MAX.	1234	COMP.	BANCO
4112	1F	REC-230	MAX.	1204	COMP.	BANCO
4113	1F	REC-230	MAX.	0234	COMP.	BANCO
4121	1F	REC-230	MAX.	1234	REC-FRO	BANCO
4122	1F	REC-230	MAX.	1204	REC-FRO	BANCO
4123	1F	REC-230	MAX.	0234	REC-FRO	BANCO
4131	1F	REC-230	MAX.	1234	FRO-VDG	BANCO
4132	1F	REC-230	MAX.	1204	FRO-VDG	BANCO
4133	1F	REC-230	MAX.	0234	FRO-VDG	BANCO
4211	1F	REC-230	MIN.	1234	COMP.	BANCO
4212	1F	REC-230	MIN.	1204	COMP.	BANCO
4213	1F	REC-230	MIN.	0234	COMP.	BANCO
4221	1F	REC-230	MIN.	1234	REC-FRO	BANCO
4222	1F	REC-230	MIN.	1204	REC-FRO	BANCO
4223	1F	REC-230	MIN.	0234	REC-FRO	BANCO
4231	1F	REC-230	MIN.	1234	FRO-VDG	BANCO
4232	1F	REC-230	MIN.	1204	FRO-VDG	BANCO
4233	1F	REC-230	MIN.	0234	FRO-VDG	BANCO

En cada caso se corren 25 simulaciones de estabilidad, con excepción de los casos 4121 y 4131, en que no se encuentra convergencia para la condición de máxima generación, por lo que se efectúan únicamente 24.

TABLA A2.4
CASOS DE FALLA MONOFASICA EN REC-400

CASO Núm.	FALLA	LUGAR	DEM.	U's	CONFIG.	DISP.
5111	1F	REC-400	MAX.	1234	COMP.	REC-FRO
5112	1F	REC-400	MAX.	1204	COMP.	REC-FRO
5113	1F	REC-400	MAX.	0234	COMP.	REC-FRO
5121	1F	REC-400	MAX.	1234	REC-FRO	REC-FRO
5122	1F	REC-400	MAX.	1204	REC-FRO	REC-FRO
5123	1F	REC-400	MAX.	0234	REC-FRO	REC-FRO
5131	1F	REC-400	MAX.	1234	FRO-VDG	REC-FRO
5132	1F	REC-400	MAX.	1204	FRO-VDG	REC-FRO
5133	1F	REC-400	MAX.	0234	FRO-VDG	REC-FRO
5211	1F	REC-400	MIN.	1234	COMP.	REC-FRO
5212	1F	REC-400	MIN.	1204	COMP.	REC-FRO
5213	1F	REC-400	MIN.	0234	COMP.	REC-FRO
5221	1F	REC-400	MIN.	1234	REC-FRO	REC-FRO
5222	1F	REC-400	MIN.	1204	REC-FRO	REC-FRO
5223	1F	REC-400	MIN.	0234	REC-FRO	REC-FRO
5231	1F	REC-400	MIN.	1234	FRO-VDG	REC-FRO
5232	1F	REC-400	MIN.	1204	FRO-VDG	REC-FRO
5233	1F	REC-400	MIN.	0234	FRO-VDG	REC-FRO

En cada caso se corren 25 simulaciones de estabilidad, con excepción de los casos 5121 y 5131, en que no se encuentra convergencia para la condición de máxima generación, por lo que se efectúan únicamente 24.

TABLA A2.5
CASOS DE FALLA MONOFASICA EN FRO-400

CASO Núm.	FALLA	LUGAR	DEM.	U's	CONFIG.	DISP.
6111	1F	FRO-400	MAX.	1234	COMP.	REC-FRO
6112	1F	FRO-400	MAX.	1204	COMP.	REC-FRO
6113	1F	FRO-400	MAX.	0234	COMP.	REC-FRO
6121	1F	FRO-400	MAX.	1234	REC-FRO	REC-FRO
6122	1F	FRO-400	MAX.	1204	REC-FRO	REC-FRO
6123	1F	FRO-400	MAX.	0234	REC-FRO	REC-FRO
6131	1F	FRO-400	MAX.	1234	FRO-VDG	REC-FRO
6132	1F	FRO-400	MAX.	1204	FRO-VDG	REC-FRO
6133	1F	FRO-400	MAX.	0234	FRO-VDG	REC-FRO
6211	1F	FRO-400	MIN.	1234	COMP.	REC-FRO
6212	1F	FRO-400	MIN.	1204	COMP.	REC-FRO
6213	1F	FRO-400	MIN.	0234	COMP.	REC-FRO
6221	1F	FRO-400	MIN.	1234	REC-FRO	REC-FRO
6222	1F	FRO-400	MIN.	1204	REC-FRO	REC-FRO
6223	1F	FRO-400	MIN.	0234	REC-FRO	REC-FRO
6231	1F	FRO-400	MIN.	1234	FRO-VDG	REC-FRO
6232	1F	FRO-400	MIN.	1204	FRO-VDG	REC-FRO
6233	1F	FRO-400	MIN.	0234	FRO-VDG	REC-FRO

En cada caso se corren 25 simulaciones de estabilidad, con excepción de los casos 6121 y 6131, en que no se encuentra convergencia para la condición de máxima generación, por lo que se efectúan únicamente 24.

APENDICE A3

TABLAS DESCRIPTIVAS DE CASOS DE PRUEBA

TABLA A3.1
CASOS DE FALLA TRIFASICA EN REC-400

CASO Núm.	FALLA	LUGAR	DEM.	U's	CONFIG.	DISP.
2111p	3F	REC-400	MAXX.	1234	COMP.	REC-FRO
2121p	3F	REC-400	MAXX.	1234	REC-FRO	REC-FRO
2131p	3F	REC-400	MAXX.	1234	FRO-VDG	REC-FRO
2211p	3F	REC-400	MED.	1234	COMP.	REC-FRO
2221p	3F	REC-400	MED.	1234	REC-FRO	REC-FRO
2231p	3F	REC-400	MED.	1234	FRO-VDG	REC-FRO
2311p	3F	REC-400	MINN.	1234	COMP.	REC-FRO
2321p	3F	REC-400	MINN.	1234	REC-FRO	REC-FRO
2331p	3F	REC-400	MINN.	1234	FRO-VDG	REC-FRO

TABLA A3.2
CASOS DE FALLA TRIFASICA EN FRO-400

CASO Núm.	FALLA	LUGAR	DEM.	U's	CONFIG.	DISP.
3111p	3F	FRO-400	MAXX.	1234	COMP.	REC-FRO
3121p	3F	FRO-400	MAXX.	1234	REC-FRO	REC-FRO
3131p	3F	FRO-400	MAXX.	1234	FRO-VDG	REC-FRO
3211p	3F	FRO-400	MED.	1234	COMP.	REC-FRO
3221p	3F	FRO-400	MED.	1234	REC-FRO	REC-FRO
3231p	3F	FRO-400	MED.	1234	FRO-VDG	REC-FRO
3311p	3F	FRO-400	MINN.	1234	COMP.	REC-FRO
3321p	3F	FRO-400	MINN.	1234	REC-FRO	REC-FRO
3331p	3F	FRO-400	MINN.	1234	FRO-VDG	REC-FRO

TABLA A3.3
CASOS DE FALLA MONOFASICA EN REC-230

CASO Núm.	FALLA	LUGAR	DEM.	U's	CONFIG.	DISP.
4111p	1F	REC-230	MAXX.	1234	COMP.	BANCO
4121p	1F	REC-230	MAXX.	1234	REC-FRO	BANCO
4131p	1F	REC-230	MAXX.	1234	FRO-VDG	BANCO
4211p	1F	REC-230	MED.	1234	COMP.	BANCO
4221p	1F	REC-230	MED.	1234	REC-FRO	BANCO
4231p	1F	REC-230	MED.	1234	FRO-VDG	BANCO
4311p	1F	REC-230	MINN.	1234	COMP.	BANCO
4321p	1F	REC-230	MINN.	1234	REC-FRO	BANCO
4331p	1F	REC-230	MINN.	1234	FRO-VDG	BANCO

TABLA A3.4
CASOS DE FALLA MONOFASICA EN REC-400

CASO Núm.	FALLA	LUGAR	DEM.	U's	CONFIG.	DISP.
5111p	1F	REC-400	MAXX.	1234	COMP.	REC-FRO
5121p	1F	REC-400	MAXX.	1234	REC-FRO	REC-FRO
5131p	1F	REC-400	MAXX.	1234	FRO-VDG	REC-FRO
5211p	1F	REC-400	MED.	1234	COMP.	REC-FRO
5221p	1F	REC-400	MED.	1234	REC-FRO	REC-FRO
5231p	1F	REC-400	MED.	1234	FRO-VDG	REC-FRO
5311p	1F	REC-400	MINN.	1234	COMP.	REC-FRO
5321p	1F	REC-400	MINN.	1234	REC-FRO	REC-FRO
5331p	1F	REC-400	MINN.	1234	FRO-VDG	REC-FRO

TABLA A3.5
CASOS DE FALLA MONOFASICA EN FRO-400

CASO Núm.	FALLA	LUGAR	DEM.	U's	CONFIG.	DISP.
6111p	1F	FRO-400	MAXX.	1234	COMP.	REC-FRO
6121p	1F	FRO-400	MAXX.	1234	REC-FRO	REC-FRO
6131p	1F	FRO-400	MAXX.	1234	FRO-VDG	REC-FRO
6211p	1F	FRO-400	MED.	1234	COMP.	REC-FRO
6221p	1F	FRO-400	MED.	1234	REC-FRO	REC-FRO
6231p	1F	FRO-400	MED.	1234	FRO-VDG	REC-FRO
6311p	1F	FRO-400	MINN.	1234	COMP.	REC-FRO
6321p	1F	FRO-400	MINN.	1234	REC-FRO	REC-FRO
6331p	1F	FRO-400	MINN.	1234	FRO-VDG	REC-FRO

APENDICE A3

ARTICULOS PRESENTADOS REFERENTES AL TRABAJO DE TESIS

ANALISIS DE ESTABILIDAD MEDIANTE REDES NEURONALES

M.C. Rogelio Ramírez Barradas

Dr. Florencio Aboytes García

Comisión Federal de Electricidad
Centro Nacional de Control de Energía
Departamento de Investigación y Desarrollo

Universidad Autónoma de Nuevo León
División de Estudios Superiores FIME
Programa Doctoral en Ingeniería Eléctrica

RESUMEN

Se propone la utilización de un conjunto de redes neuronales para evaluar la seguridad dinámica en la operación de la red eléctrica asociada a la planta carboeléctrica Río Escondido, localizada en el Área de Control Noreste de Comisión Federal de Electricidad.

Se presentan los criterios de selección y agrupación de los patrones de entrenamiento y de prueba.

Los resultados obtenidos confirman la factibilidad de aplicar la técnica de redes neuronales en el análisis de estabilidad transitoria.

INTRODUCCION

Un problema importante en la operación de los Sistemas Eléctricos de Potencia (SEP) es el determinar el nivel de seguridad tanto en estado estable como transitorio, para prevenir la ocurrencia de disturbios, tomando las medidas precautorias convenientes. Existen actualmente métodos algorítmicos eficientes que ofrecen índices de seguridad en estado estable, pero que no proporcionan información con respecto al comportamiento dinámico del sistema [1].

Artículo presentado en el SIEEEM-93, organizado por la Sección Monterrey del IEEE, del 11 al 13 de Octubre de 1993 en Monterrey, N.L.

El análisis de seguridad en estado estable da por hecho que después de un disturbio el sistema es capaz de llegar a un nuevo punto de operación estable, limitándose a verificar que en la nueva condición no se violen las restricciones operativas de voltajes nodales y flujos en líneas de transmisión.

El análisis dinámico permite determinar lo que sucede en la transición hacia ese nuevo punto, y a la vez definir si es un punto de operación factible. Las posibilidades de llegar a estado estable disminuyen si la contingencia es crítica, o si la red de transmisión es débil.

El evento inicial de un disturbio puede ser desde la pérdida accidental de un elemento, que no impacte las variables voltaje y frecuencia, hasta una falla sólida no liberada adecuadamente, cuyos efectos se propagan a todo el sistema. En cualquier caso, el primer evento ocasiona un desbalance de energía que se traduce en variaciones de voltaje, frecuencia y flujos de potencia en líneas de transmisión. Una falla en los sistemas de protección o la imposibilidad de neutralizar el desbalance ocasionará problemas de pérdida de sincronismo en generadores, caída transitoria de voltaje en nodos importantes o la apertura no deseada de enlaces por la operación errónea de relevadores.

Para el análisis, fuera de línea, del comportamiento dinámico de un sistema eléctrico, se han utilizado programas digitales de estabilidad transitoria, con los que se simula la ocurrencia de disturbios y los resultados se traducen en guías operativas. Por lo general sólo se realiza este tipo de análisis para las contingencias más críticas, bajo condiciones de demanda típicas y considerando una sola topología de la red; debido a la imposibilidad de simular todas las posibles contingencias en todas las condiciones operativas del sistema.

El mayor obstáculo para realizar este tipo de análisis en línea es el tiempo disponible para hacerlo, ya que se deberían simular una gran cantidad de casos en un tiempo reducido (10 min. promedio). Enseguida se mencionan algunas de las alternativas para resolver este problema, así como los pros y contras que cada una presenta.

a) El empleo de supercomputadoras.

Ventajas: Rapidez de procesamiento, utilización de algoritmos existentes.

Desventajas: Alto costo, formato especial de datos.

b) La utilización de equipos tipo estación de trabajo, combinados con el empleo de técnicas de equivalentes.

Ventajas: Rapidez de procesamiento.

Desventaja: Necesidad de desarrollar e implementar nuevas técnicas de equivalentes dinámicos.

c) Emplear los métodos de la función de energía.

Ventajas: Obtención directa de índices de estabilidad.

Desventajas: Necesidad de utilizar algoritmos convencionales para definir los casos de interés

d) Utilizar sistemas basados en conocimiento: sistemas expertos o redes neuronales.

Ventajas: Rapidez de respuesta, capacidad de generalizar.

Desventajas: Basados en técnicas heurísticas.

En este trabajo se propone la utilización de una red neuronal, que "aprende" la información de una serie de casos de estudio realizados previamente, y que una vez entrenada, para cada nueva condición de operación obtenga una estimación directa del nivel de seguridad en tiempo real.

APLICACIONES DE REDES NEURONALES EN SEP's

Una red de neuronas artificiales es una herramienta de cómputo diseñada en base a los principios de operación de las neuronas biológicas. Aún cuando desde 1890 la psicología había determinado la forma en que ocurren los procesos de información en el cerebro [2], no es sino hasta 1943 cuando se presentó el primer modelo formal de una neurona artificial [3], y en 1982 al mostrarse las implicaciones prácticas de los sistemas basados en redes neuronales [4], se inicia un período de intensa actividad de investigación en diversas áreas de la tecnología.

Los problemas en que es posible aplicar redes neuronales son aquellos que implican procesos de clasificación, asociación, toma de decisiones y razonamiento [5]. No debe esperarse que una red neuronal resuelva eficientemente problemas que involucran cálculo algorítmico.

Las redes de neuronas artificiales se pueden clasificar de acuerdo a tres de sus principales características:

- 1) Tipo de neurona artificial
- 2) Arquitectura de la red
- 3) Regla de aprendizaje

El primer aspecto se refiere al modelo matemático que

se elige para la neurona artificial; a través del modelo se calcula la salida de la unidad de procesamiento en función de las entradas. Por arquitectura de la red se entiende la forma en que se interconectan las neuronas, y por último la regla de aprendizaje es el algoritmo por medio del cual se modifica la forma en que la neurona responde a entradas determinadas.




Fig. 1 Representación simplificada de una neurona biológica.

La Figura 2 muestra en forma esquemática un modelo general de neurona artificial. En la unidad de procesamiento, que equivale al núcleo de una neurona biológica, se aplica una función no lineal a la sumatoria ponderada de las entradas. La función sigmoideal es una función no lineal típica que se aplica en este caso:

$$f(s) = \frac{1}{1 + e^{-s/\theta_0}}; \quad s = W^T X$$

donde la variable θ_0 regula la inclinación de la curva sigmoideal.

Se han ideado diversas formas de interconexión de las unidades de procesamiento, algunas procesan la información en una sola dirección entrada-salida, mientras que otras incluyen retroalimentación de las señales de salida como entrada a otras unidades. La arquitectura de la red influye en la elección del algoritmo de aprendizaje.




Fig. 2 Modelo general de neurona artificial.

Las investigaciones relacionadas con redes neuronales, en el campo de los Sistemas Eléctricos de Potencia han abordado, entre otros, los siguientes temas: Pronóstico de carga

[6], identificación de armónicas [7], control de generadores síncronos [8], identificación de fallas [9], análisis de estabilidad en estado estable [10], evaluación de seguridad [11-14] y estabilidad dinámica [15].

SISTEMA DE PRUEBA

El sistema de prueba consiste en la red de 400 KV asociada a la central Río Escondido, ubicada en el norte del país. La Figura 3 muestra un diagrama unifilar representativo de la zona.




Fig. 3 Diagrama unifilar del área de interés.

Las plantas Río Escondido (REC) y Carbón dos (CBD), generan energía eléctrica utilizando carbón como combustible. La primera de ellas cuenta con cuatro unidades de 300 MW de capacidad, mientras que la segunda tiene una unidad de 350 MW, a la que se añadirá otra en el futuro. La energía eléctrica se transporta a los puntos de consumo a través de dos líneas de 400 KV y cuatro de 230 KV. El número de líneas en la red de 230 KV se reduce al alejarse de la planta, con lo que se crean cuellos de botella para la transmisión de potencia.

Para el operador de esta red sería deseable contar con una herramienta que le indicara que tan seguro es operar las plantas mencionadas con un nivel de generación dado, o que le recomendara la generación a asignar a las plantas para asegurar que no se presentarán problemas de sincronismo si ocurre cualquiera de las fallas analizadas.

CASOS DE ESTUDIO

Es posible plantear una gran cantidad de casos de estudio de estabilidad considerando las variables implicadas en el problema. Además del monto de generación de las unidades de Río Escondido, que será la variable de control, se tienen las siguientes:

- La falla, que puede ser de varios tipos y ocurrir en sitios aleatorios de la red.
- El nivel instantáneo de la demanda, que depende del día y la hora que se elija para el estudio.
- La configuración del sistema, esto es las unidades generadoras, líneas de transmisión y transformadores conectados.
- Otras variables a considerar podrían ser los

parámetros de los sistemas de excitación de las unidades, la generación de otras unidades del sistema, etc.

Debido a la topología de la red asociada a la planta Río Escondido y considerando la experiencia obtenida en su operación se puede reducir el universo de casos posibles y analizar un pequeño conjunto, que incluya los casos críticos. En la definición de los casos de estudio se considerarán las siguientes variables:

- 6 Tipos de fallas.
- 2 Montos de demanda.
- 3 Configuraciones de la red.
- 3 Configuraciones de generación.

En forma detallada:

FALLAS:

- Falla trifásica en REC-230.
- Falla trifásica en REC-400.
- Falla trifásica en FRO-400.
- Falla monofásica en REC-230.
- Falla monofásica en REC-400.
- Falla monofásica en FRO-400.

DEMANDAS:

- Demanda máxima.
- Demanda mínima.

CONFIGURACIONES DE RED:

- Red completa.
- Una LT REC-400-FRO desconectada.
- Una LT FRO-400-VDG desconectada.

CONFIGURACIONES DE GENERACION:

- Cuatro unidades en la planta.
- Una unidad de REC-230 desconectada.
- Una unidad de REC-400 desconectada.

De la combinación de las condiciones anteriores se obtienen 108 casos, por ejemplo, los casos 1 y 11 se especificarían como sigue:

Caso 1.- Falla trifásica en REC-230 en demanda máxima con red completa y todas las unidades en la planta.

Caso 11.- Falla trifásica en REC-400 en demanda mínima, con una línea de REC-400 a FRO-400 fuera de servicio y todas las unidades en la planta

Para mostrar gráficamente los resultados de los casos, se define un espacio de generación de 25 pares (X,Y); donde X es la generación de las unidades conectadas a 230 KV en la planta Río Escondido y Y es la generación de las unidades conectadas en 400 KV. Considerando que la generación puede cambiar en pasos discretos de 50 MW, y que 100 MW es la mínima generación permitida por unidad, se obtiene el espacio de generación que se muestra en la Figura 4.

Analizando seis tipos de falla, para dos niveles de demanda, tres diferentes configuraciones de la red y tres configuraciones de generación, se originan 2700 estudios de estabilidad, al barrer un espacio de generación de 25 puntos.




Fig. 4 Ejemplo de espacio de generación.

Como resultado principal de los análisis de estabilidad se obtiene la variación angular de los rotores de los generadores del sistema con respecto a una máquina de referencia. Por medio de estos resultados se pueden separar los casos estables de los inestables y mostrar gráficamente dentro del espacio de generación. La Figura 5 muestra la variación angular de la unidad REC-U2 cuando en el sistema ocurre la falla descrita por el caso 1.




Fig. 5 Diferencia angular de REC-U2. Caso 1.

Para una condición de operación, fijada por la demanda del sistema y la configuración de la red, se tendrán puntos del espacio de generación que no deben ser ocupados si no se quiere correr el riesgo de inestabilidad ante diferentes contingencias. Una contingencia define un patrón de estabilidad dentro del espacio de generación. Los puntos negros en la Figura 6 indican puntos de operación en los que las unidades conectadas en 400 KV pierden estabilidad cuando ocurre la contingencia del caso 11 y definen también los límites

de la zona de operación segura.




Fig. 6 Límites de estabilidad para las unidades conectadas en 400 KV, para la contingencia 11.

En la Figura 7 se muestra el patrón de estabilidad obtenido para las unidades conectadas en 230 KV. Al superponer los patrones de estabilidad de las Figuras 6 y 7 se obtendrá la zona de seguridad total de la planta para esta contingencia.

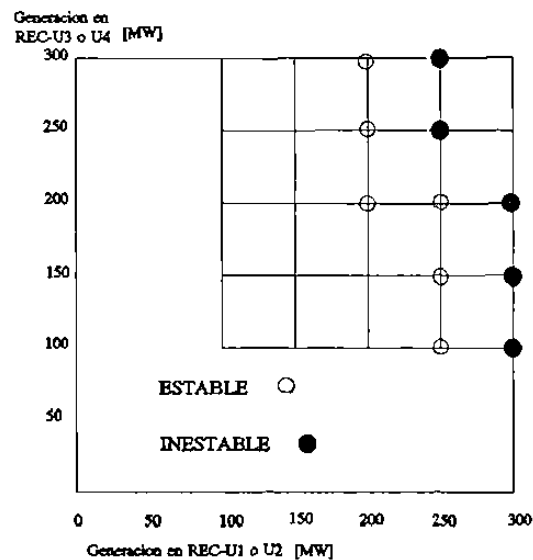


Fig. 7 Límites de estabilidad para las unidades conectadas en 230 KV. Caso 11.

La información de los patrones de estabilidad se puede almacenar fácilmente en forma matricial y recuperar instantáneamente mostrando los patrones correspondientes a la condición requerida, lo cual puede ser una ayuda gráfica para comprender la gravedad de una o más contingencias, considerando el área factible en la que se puede operar.

Los patrones de estabilidad sintetizan los resultados de una gran cantidad de estudios, sin embargo lo que se requiere es una herramienta que además de tener la capacidad de clasificar los resultados (estable-inestable), pueda generalizar la base de conocimiento y ofrecer una respuesta plausible para aquellos casos que no se simulan. Las redes neuronales han mostrado ser útiles en problemas con estas características.

DEFINICION DE VARIABLES DE ENTRADA A LA RED NEURONAL

El primer punto a resolver al atacar un problema por medio de redes neuronales es la elección de la red más adecuada y la determinación de sus parámetros. En este caso se optó por utilizar el algoritmo de retropropagación del error con una red de tres niveles, con una capa interna.

Como variables de entrada a la red se eligieron aquellas que se consideraron más significativas para el comportamiento dinámico de la planta, y son las siguientes:

- 1.- Potencia activa inicial.
- 2.- Potencia activa promedio durante la aplicación de la falla.
- 3.- Potencia activa de postfalla.
- 4.- Derivada de la potencia activa de postfalla.
- 5.- Potencia reactiva inicial.
- 6.- Potencia reactiva promedio durante la falla.
- 7.- Potencia reactiva de postfalla.
- 8.- Derivada de la potencia reactiva de postfalla.
- 9.- Posición angular inicial.
- 10.- Aceleración promedio durante la falla.
- 11.- Aceleración de postfalla.
- 12.- Derivada de la aceleración de postfalla.
- 13.- Configuración.
- 14.- Demanda.
- 15.- Número de unidades conectadas en 230 KV.
- 16.- Número de unidades conectadas en 400 KV.

Las variables de salida se definieron como la posición angular máxima durante el tiempo de estudio y el tiempo al que ésta ocurre. De esta manera, la red a utilizar debería tener 16 elementos de entrada y dos de salida. El número de elementos en la capa interna se define heurísticamente y depende en gran medida de la complejidad de la función que la red trata de representar.

RESULTADOS

El aprendizaje de la red se mejora cuando los resultados se le presentan con una escala adecuada y se aprovechan las características de procesamiento paralelo de información, dividiendo el problema en varios subproblemas y utilizando por tanto varias redes.

De acuerdo a las consideraciones anteriores los resultados se agruparon separando aquellos obtenidos para las unidades conectadas en 400 KV y los de las unidades que se conectan en 230 KV. Además se definieron 16 sub-espacios de generación, formados por los cuadrados mostrados en la Figura 3, con lo que se logra dividir el problema entre dos grupos de redes neuronales, cada grupo compuesto de 16 redes. Esto

hace que cada red neuronal se "especialice" en un determinado sub-espacio de generación, para un voltaje dado, con lo que se reduce la carga de los patrones a aprender por cada red.

Considere el espacio de generación de la Figura 4. En cada uno de los 25 puntos de operación, mostrados con un círculo, se realizaron 108 estudios de estabilidad, lo que equivale al mismo número de patrones entrada-salida. En un subespacio de generación se tienen por lo tanto 432 de estos patrones. Dos tercios de ellos, elegidos aleatoriamente, se separan y constituyen el conjunto de patrones de entrenamiento para la red neuronal. El tercio restante se utiliza como conjunto de patrones de prueba.

El algoritmo de aprendizaje de retropropagación del error se implementó utilizando el paquete computacional MATLAB versión 3.1. Se utilizaron 10 neuronas internas en cada una de las 32 redes y el proceso de aprendizaje se detuvo automáticamente cuando el error en los patrones de prueba comenzó a aumentar, indicando esto que la red dejaba de generalizar adecuadamente.

La Tabla 1 muestra los porcentajes de error obtenidos con los patrones de entrenamiento y los de prueba para las redes que procesaron la información de las unidades generadoras conectadas en 400 KV. La Tabla 2 muestra los resultados correspondientes para las redes de las unidades conectadas en 230 KV.

TABLA 1
PORCENTAJES DE ERROR PARA REDES ASOCIADAS A UNIDADES EN 400 KV

RED	ITER	ϵ entrena [%]	ϵ prueba [%]
1	23	0.986	4.53
2	32	0.700	2.48
3	21	0.946	1.46
4	5	5.300	7.55
5	29	0.637	1.78
6	32	0.650	1.86
7	7	4.277	13.70
8	60	1.600	3.12
9	4	4.480	5.61
10	4	6.000	12.49
11	21	1.148	1.29
12	41	1.537	3.22
13	6	2.361	10.93
14	21	1.572	2.96
15	23	1.200	2.52
16	25	2.810	6.27

Se observa en la Tabla 1 que en general los errores de

prueba son mayores que los errores de entrenamiento, y que los mayores errores están relacionados con un número reducido de iteraciones en el proceso de aprendizaje. Los errores elevados también indican que la complejidad del mapeo en estos subespacios es mayor. Estos errores se podrían disminuir utilizando un número mayor de unidades en la capa interna, o utilizando en estos casos dos redes neuronales: Una para clasificar los valores angulares máximos y otra para clasificar los tiempos en que estos ocurren.

Si se considera un error máximo del 5% en los patrones de prueba, solo será necesario reentrenar a 6 de las 16 redes de la tabla 1.

TABLA 2
PORCENTAJES DE ERROR PARA REDES ASOCIADAS A UNIDADES EN 230 KV

RED	ITER	ϵ entrena [%]	ϵ prueba [%]
1	19	0.48	0.77
2	23	0.88	0.92
3	37	0.53	0.76
4	24	1.30	2.00
5	23	0.37	0.65
6	23	0.57	1.10
7	24	0.95	1.06
8	13	1.50	1.55
9	28	1.00	0.98
10	10	2.06	2.22
11	18	1.48	1.24
12	14	1.70	2.19
13	9	3.78	3.16
14	5	5.17	3.36
15	13	3.51	2.37
16	21	2.65	2.31

En el caso de la Tabla 2, se observa que no será necesario aumentar el número de neuronas en la capa interna, puesto que se obtienen errores de prueba menores al 5%.

CONCLUSIONES

Se muestra la factibilidad de aplicar la técnica de redes neuronales al problema de análisis de seguridad dinámica.

Las redes neuronales permiten generalizar a partir de casos conocidos, logrando errores pequeños para aquellos casos no presentados en la etapa de entrenamiento.

Los espacios de generación permiten mostrar gráficamente los patrones de estabilidad, y relacionar la gravedad de una contingencia con el número de puntos de operación seguros.

La rapidez de respuesta de las redes neuronales, una vez entrenadas, hace factible su utilización en tiempo real, auxiliando al operador del sistema eléctrico.

La exposición presentada cubre una alternativa de solución, planteándose futuros estudios con diferentes algoritmos de aprendizaje, o evaluando otras técnicas relacionadas con el reconocimiento de patrones.

REFERENCIAS

- [1] N. Balu et al, "On-Line Power System Security Analysis", Proc. of the IEEE, Vol. 80, No. 2, Feb. 1992.
- [2] W. James, "Association", Chapter XVI in Psychology (Briefer Course), New York, Holt.
- [3] W. McCulloch, W. Pitts, "A Logical Calculus of the ideas Immanent in Nervous Activity", Bulletin of Mathematical Biophysics 5.
- [4] J.J. Hopfield, "Neural Networks and Physical Systems with Emergent Collective Computational Abilities", Proceedings of the National Academy of Sciences 79.
- [5] J.M. Zurada, Introduction to Artificial Neural Systems, West Publishing Company, 1992. Chapter 1.
- [6] D.C. Park, M.A. El-Sharkawi, R.J. Marks II, "Electric Load Forecasting Using an Artificial Neural Network", IEEE Trans. on Power Syst., Vol. 6, No. 2, May 1991.
- [7] R.K. Hartana, G.G. Richards, "Harmonic Source Monitoring and Identification using Neural Networks", IEEE Trans. on Power Syst., Vol. 5, No. 4, Nov. 1990.
- [8] I. Mushin, M.K. Sundareshan, S.I. Sudharsanan, A. Karakasoglu, "Adaptive Excitation and Governor Control of Synchronous Generators using Multilayer Recurrent Neural Networks", Proc. of the 31st Conf. on Decision and Control, Tucson, Arizona, Dec. 1992.
- [9] N. Kandil, V.K. Sood, K.Khorasani, R.V. Patel, "Fault Identification in an AC-DC Transmission System using Neural Networks", IEEE Trans. on Power Systems, Vol. 7, No.2, May 1992.
- [10] Chao-Rong Chen, Yuan-Yih Hsu, "Synchronous Machine Steady-State Stability Analysis using an Artificial Neural Network", IEEE Trans. on Energy Conversion, Vol. 6, No. 1, March 1991.
- [11] D.J. Sobajic, Yoh-Han Pao, "Artificial Neural-Net based Dynamic Security Assessment for Electric Power Systems", IEEE Trans. on Power Systems, Vol 4, No.1, Feb. 1989.
- [12] Yoh-Han Pao, D.J. Sobajic, "Combined use of Unsupervised and Supervised Learning for Dynamic Security Assessment", Trans. on Power Systems, Vol 7, No.2, May 1992.

- [13] M. Aggoune, M.A. El-Sharkawi, D.C. Park, R.J. Marks III, "Preliminary Results on Using Artificial Neural Networks for Security Assessment", IEEE Trans. on Power Systems, Vol. 6, No. 2, May 1991.
- [14] D. Niebur, A.J. Germond, "Power System Static Security Assessment using the Kohonen Neural Network Classifier", IEEE Trans. on Power Systems, Vol. 7, No. 2, May 1992.
- [15] H. Mori, Y. Tamaru, S. Tsuzuki, "An Artificial Neural-Net based Technique for Power System Dynamic Stability with the Kohonen Model", Trans. on Power Systems, Vol. 7, No. 2, May 1992.

Dr. Florencio Aboytes García. Ingeniero Mecánico Electricista y Maestro en Ciencias del Instituto Tecnológico y de Estudios Superiores de Monterrey en 1968 y 1969. Doctorado en Ingeniería Eléctrica en el Imperial College of Science and Technology de Londres, Inglaterra en 1974. Desde 1975 trabaja en Comisión Federal de Electricidad donde ha ocupado diversos puestos técnicos en la Gerencia de Estudios y la Gerencia del Centro Nacional de Control de Energía (CENACE). Actualmente es Jefe del Departamento de Investigación y Desarrollo del CENACE.

Adicionalmente desde 1975 ha impartido cursos de postgrado y dirigido trabajos de investigación en la Sección de Graduados de ESIME-IPN, la División de Estudios de Postgrado de la UNAM, y en el Programa de Doctorado de la Facultad de Ingeniería Mecánica y Eléctrica de la UANL. Actualmente es Presidente del Comité Doctoral de FIME-UANL.

Es Senior Member del IEEE, miembro de CIGRE y forma parte del Sistema Nacional de Investigadores desde 1985.

M.C. Rogelio Ramírez Barradas. Obtuvo la licenciatura en Ingeniería Eléctrica por el Instituto Politécnico Nacional en 1984 y la Maestría en Ciencias por la Universidad Autónoma de Nuevo León en 1989. Desde 1984 labora en el Centro Nacional de Control de Energía de CFE, estando actualmente comisionado al Programa Doctoral en Ingeniería Eléctrica en Monterrey, N.L.

Sus principales áreas de interés son la operación de Sistemas Eléctricos de Potencia, los Sistemas Expertos y las Redes Neuronales.

APLICACION DE REDES NEURONALES EN LA EVALUACION DE LA ESTABILIDAD DE SISTEMAS ELECTRICOS DE POTENCIA

F. Aboytes

R. Ramírez

Unidad de Ingeniería Avanzada, Centro Nacional de Control de Energía
Comisión Federal de Electricidad, México.

Programa Doctoral en Ingeniería Eléctrica, Facultad de Ingeniería Mecánica y Eléctrica
Universidad Autónoma de Nuevo León, Monterrey, N.L., México.

Resumen. Se presentan resultados sobre la aplicación de la metodología de Redes de Neuronas Artificiales al problema de evaluación de la seguridad dinámica en un Sistema Eléctrico de Potencia Longitudinal, incluyendo la activación de controles discretos suplementarios. Se investigan diferentes formas de representación del espacio de entrenamiento, así como diferentes alternativas de selección de la arquitectura de las redes. Se propone una metodología sistemática para la generación de los patrones del espacio de entrenamiento, la síntesis de resultados en forma de espacios de generación y la separación de los patrones de entrenamiento por tipo de falla, de manera de aprovechar las características inherentes al comportamiento de los sistemas basados en Redes de Neuronas Artificiales.

I. INTRODUCCION

La determinación en línea del nivel de seguridad dinámica es un problema de gran importancia en la operación de Sistemas de Potencia. Debido a los cambios constantes en las condiciones de operación reales, (demanda, topología, generación), su evaluación es una función que debe realizarse en forma continua. La solución del problema requiere determinar rápidamente el comportamiento dinámico del sistema ante una serie de contingencias previstas, en las que se debe considerar la posible activación de controles discretos suplementarios (CDS).

Conferencia invitada al Simposium del Instituto de Ingenieros en Electricidad y Electrónica, Sección Monterrey, SIEEEM-94, efectuado del 24 al 26 de Octubre de 1994 en Monterrey, N.L.

En redes eléctricas longitudinales, donde existen restricciones en la transmisión de energía, el problema de estabilidad se presenta entre regiones de generación apartadas y centros de carga. La característica radial de estas regiones de generación hace que el desarrollo del problema transitorio sea muy rápido y pueda ser definido, en general, en la primera oscilación. La operación del sistema en estas condiciones requiere la implementación de medidas preventivas adecuadas. Los CDS's han mostrado ser un medio eficaz para mejorar la estabilidad, permitiendo operar los sistemas de transmisión más cerca de sus límites.

La importancia del problema planteado se refleja en las diversas alternativas sugeridas para abordarlo [1]. Entre otras, se mencionan las siguientes: La implementación de los algoritmos de solución de estabilidad transitoria en el dominio del tiempo, en computadoras más poderosas [2], la utilización de métodos directos [3], sistemas expertos [4-8], métodos de reconocimiento de patrones [9-12], métodos probabilísticos [13] y redes de neuronas artificiales (RNA) [14-17].

En este artículo se propone la utilización de sistemas basados en conocimiento (SBC) para abordar el problema de la estimación en línea, de la estabilidad transitoria de sistemas eléctricos de potencia (SEP) longitudinales. Se diseña un sistema basado en conocimiento compuesto de doce redes de neuronas artificiales, operando en paralelo, para estimar la estabilidad en el Area Noreste del Sistema Interconectado Mexicano.

Se deriva heurísticamente un índice de estabilidad binario y se le utiliza como variable de salida para una interfaz gráfica. El SBC auxilia al operador del sistema a decidir cambios de generación y/o activación de controles discretos, al mostrar los esquemas de estabilidad/inestabilidad. Se presenta un ejemplo de esta aplicación.

II. APLICACION DE RNA's EN ESTUDIOS DE ESTABILIDAD TRANSITORIA

Los principales requerimientos para la determinación en línea del nivel de seguridad dinámica son rapidez y exactitud. Las RNA's constituyen una alternativa viable por su rapidez de respuesta, el objetivo de este estudio es analizar su capacidad para proveer respuestas confiables.

La aplicación de la metodología de redes de neuronas artificiales al problema de estimación de los niveles de seguridad dinámica consta de las siguientes etapas:

- o Generación de patrones de entrenamiento y prueba.
- o Selección de variables de entrada/salida.
- o Selección del tipo de RNA a emplear.
- o Entrenamiento y prueba de las RNA's

A. Generación de Patrones de Entrenamiento y Prueba

En esta etapa es importante obtener un conjunto de patrones de entrenamiento que represente adecuadamente el espacio de posibles condiciones de operación. En estado estable las diferentes condiciones operativas se generan considerando cambios en los niveles de demanda, generación y topología, por ejemplo. Los posibles estados dinámicos se generan considerando diferentes fallas en varios puntos de la red.

La capacidad de aprendizaje de las RNA's depende de la complejidad del problema y del número y organización de los patrones de entrenamiento. Es posible reducir la dimensión del conjunto total estableciendo grupos de datos independientes. En sistemas longitudinales es posible acotar el número de casos debido a la naturaleza regional del problema.

Los patrones se pueden generar por medio de estudios de estabilidad en el tiempo o utilizando métodos directos.

B. Selección de Variables de Entrada/Salida

La selección de las variables que forman parte de los patrones de entrenamiento y prueba se puede realizar por medio de consideraciones prácticas, derivadas del conocimiento del sistema bajo estudio o a través de análisis estadísticos, como los empleados por las técnicas de reconocimiento de patrones [18]. En estudios previos sobre el tema se han utilizado diferentes variables de entrada de estado estable y dinámicas. La variable de salida más común ha sido el tiempo crítico de liberación de falla. La consideración importante es que, sin importar el tipo de variables que se elijan, estas deben ser escaladas adecuadamente.

C. Selección del Tipo de RNA a emplear

De acuerdo al tipo de entrenamiento, las redes se pueden clasificar como de aprendizaje supervisado y no supervisado. A su vez, en cuanto al flujo de información en la misma, se pueden catalogar como de procesamiento progresivo o con retroalimentación.

Para el problema que se aborda es conveniente utilizar redes de procesamiento progresivo con entrenamiento supervisado. Estas redes pueden estar constituidas por varias capas o niveles de elementos.

D. Entrenamiento y Prueba de las RNA's

El entrenamiento de las RNA's es un proceso iterativo, en el que se reduce progresivamente la suma del error cuadrático. Es posible fijar el número de iteraciones o definir una cierta tolerancia de error para detener el algoritmo. La prueba de las RNA's se puede realizar en cada iteración, si se desea, o al finalizar el proceso de entrenamiento.

III. CASO DE ESTUDIO

Se describen enseguida las características del sistema de prueba, y se detallan las etapas del proceso de aplicación de la metodología de RNA's, para este caso.

A. Sistema de Prueba

El sistema de prueba (227 nodos, 330 ramas, 53 generadores), forma parte de la red de 230 y 400 kV del área Noreste, que es una de las 8 en que se divide operativamente la red eléctrica de México. La Fig. 1 muestra el diagrama unifilar simplificado del área Noreste.




Fig. 1 Diagrama unifilar del área de interés.

Los problemas de estabilidad del área Noreste están ligados de manera estrecha con la operación de las centrales carboeléctricas Río Escondido (REC) y Carbón Dos (CBD), ubicadas en el estado de Coahuila, cerca de la frontera norte del país. La primera de ellas cuenta con cuatro unidades de 300 MW de capacidad, mientras que la segunda tiene una unidad de 350 MW. La energía de estas centrales se extrae por dos líneas en 400 kV y cuatro en 230 kV.

B. Patrones de Entrenamiento y Prueba

Por medio de estudios de estabilidad en el tiempo se generaron un total de 2700 patrones de entrenamiento, considerando las siguientes variables:

- 6 Tipos de fallas.- Falla monofásica y trifásica en 3 nodos de la red.
- 2 Magnitudes de demanda.- Máxima y mínima.
- 3 Configuraciones de la red.- Sin líneas fuera de operación y con dos líneas fuera (alternadamente).
- 3 Configuraciones de generación.- Planta con 4 unidades o con tres unidades (Una en 230 kV o una en 400 kV).
- 25 Combinaciones de generación.- Considerando 5 niveles para las unidades en 230 kV y 5 niveles para las unidades en 400 kV (100, 150, 200, 250 y 300 MW).

Además se crearon 540 casos adicionales de prueba, considerando las siguientes condiciones:

- 6 Tipos de fallas. Fallas trifásicas y monofásicas en REC-230, REC-400 y FRO-400.
- 3 Magnitudes de demanda.- Media, máxima+10% y mínima-10%
- 3 Configuraciones de la red.
- 10 Combinaciones de generación.

C. Variables de Entrada/Salida

Se seleccionaron 12 variables para especificar los patrones de entrada:

- o Potencia activa generada en 230 y 400 kV por una unidad en cada nivel de voltaje.
- o Potencia reactiva generada en 230 y 400 kV
- o Posición angular inicial en 230 y 400 kV
- o Número de unidades en cada nivel de voltaje
- o Nivel de la demanda
- o Topología: a) Red completa, b) LT REC-FRO fuera, c) LT FRO-VDG fuera

Se derivó un índice de estabilidad binario, basado en el comportamiento angular de las unidades, para ser utilizado como variable de salida. A los casos inestables se les asignó el valor (1), y a los estables un valor (0).

La normalización utilizada para las variables de entrada es en el intervalo (-1, 1).

D. Arquitectura de Redes de Neuronas Artificiales

Se probaron diferentes arquitecturas de redes de procesamiento progresivo de una y dos capas ocultas, así como variantes en la forma de la salida, considerando los casos críticos en forma separada (críticamente estable y críticamente inestable). Los mejores resultados se obtuvieron con redes de una capa oculta y un elemento binario de salida (estable/inestable), como la que se muestra en la Fig. 2.




Fig. 2 Arquitectura empleada.

E. Proceso de Entrenamiento y Prueba

Para el entrenamiento se utilizó el algoritmo de retropropagación de error con paso adaptivo [19]. El entrenamiento se da por terminado al alcanzar una tolerancia de error de 0.2%, o si al llegar a 250 iteraciones se detecta haber pasado un mínimo en el error de prueba.

La presentación de los patrones de prueba se realizó durante el proceso de entrenamiento para cada red.

IV. ANALISIS DE RESULTADOS

La capacidad de aprendizaje de las redes se probó agrupando los conjuntos de patrones de entrada/salida con dos criterios diferentes:

Criterio de Agrupación 1: Separar los patrones de acuerdo al tipo de falla y al nivel de voltaje de las unidades. Siendo 6 tipos de falla y dos niveles de voltaje

se forman 12 grupos. Cada grupo se compone de 450 patrones, los cuales se obtienen de las combinaciones de la demanda (2), configuración de la red (3), configuración de la generación (3) y combinaciones de generación (25). La Tabla 1 muestra el número de casos de entrenamiento y de prueba por categoría de clasificación. En cada grupo se eliminaron dos casos sin convergencia del estado inicial.

Criterio de Agrupación 2: Agrupar los patrones de acuerdo a niveles de generación y por voltaje. Considerando 5 niveles de generación para las unidades en 230 kV y 400 kV se obtienen 16 grupos de generación para cada nivel de voltaje, esto es, 32 grupos. Los grupos de generación se muestran en la Fig. 3.




Fig. 3 Grupos de generación.

TABLA 1
Número de Casos por Categoría. Criterio 1.

Grupo Núm.	Entrenamiento		Prueba	
	Estab.	Inest.	Estab.	Inest.
1	388	60	76	12
2	231	217	23	65
3	266	182	29	59
4	446	2	88	0
5	301	147	44	44
6	310	138	52	36
7	416	32	77	11
8	227	221	18	70
9	258	190	28	60
10	440	8	88	0
11	296	152	44	44
12	306	142	49	39
Total	3885	1491	616	440

En este caso, cada grupo tiene 432 patrones. En cada una de las 4 aristas de una región de generación se simulan 108 casos variando: falla (6), demanda (2), configuración de la red (3) y configuración de generación (3). La Tabla 2 muestra el número de casos de entrenamiento, separados por categoría, para cada grupo.

De acuerdo a una regla empírica de las técnicas de reconocimiento de patrones [9], el número de patrones por clase debe ser al menos 10 veces mayor que el número de variables de entrada. Siendo 12 las variables de entrada, se deberían tener un mínimo de 120 casos por categoría. De aquí que se tendrían dificultades en la clasificación de patrones para los grupos con menos de 120 casos estables o inestables.

En la Tabla 1 los grupos 1 a 6 contienen la información de estabilidad para las unidades conectadas a 230 kV, y los grupos 7 a 12 corresponden a las unidades en 400 kV. En la Tabla 2, los grupos 1 a 16 contienen la información de las unidades en 230 kV y los grupos 17 a 32 la correspondiente a las unidades en 400 kV.

TABLA 2
Número de Casos por Categoría. Criterio 2.

Grupos Núm.	Unidades en 230 kV		Unidades en 400 kV	
	Estables	Inest.	Estables	Inest.
1,17	392	40	387	45
2,18	359	73	359	73
3,19	342	90	342	90
4,20	306	126	329	103
5,21	361	71	354	78
6,22	342	90	339	93
7,23	331	101	329	103
8,24	286	146	308	124
9,25	344	88	339	93
10,26	331	101	329	103
11,27	312	120	310	122
12,28	252	180	270	162
13,29	329	103	311	121
14,30	307	125	291	141
15,31	273	159	256	176
16,32	205	227	205	227

A. Resultados Utilizando Criterio 1

Se realizaron pruebas variando el número de elementos en la capa oculta desde 1 a 10. Los mejores resultados se obtuvieron para redes con más de 4 elementos en la capa oculta. En la Tabla 3 se reportan los valores alcanzados por la suma cuadrática de error de entrenamiento para estas redes. El error promedio para todas las redes se indica en el último renglón. Las redes con ocho y nueve elementos en la capa interna obtienen el mínimo error promedio.

El error máximo es de 1.49% para la red del grupo nueve, con seis elemento en la capa interna, mientras que el mínimo error, 0.03%, se obtiene en las redes de 5,8 y 9 elementos en la capa interna a las que se presentan los patrones del grupo cuatro. La Tabla 4 muestra la suma cuadrática de errores para la etapa de prueba. En este caso, el mínimo error promedio se obtiene por las redes con 10 elementos en la capa interna.

La Tabla 5 muestra el porcentaje de errores de clasificación para SBC's de 12 redes con el mismo número de neuronas en la capa interna (NNCI). El total de patrones de entrenamiento y prueba para cada SBC es de 5400 y 1056 respectivamente. F.A. indica falsa alarma o sea caso estable clasificado como inestable, F.E.E. indica falso estado estable o sea caso inestable clasificado como estable, T es el total de errores.

TABLA 3
Errores de Entrenamiento (Criterio 1) [%]

Grupo Núm	Número de Elementos en Capa Interna					
	5	6	7	8	9	10
1	0.30	0.29	0.23	0.29	0.22	0.26
2	0.96	1.02	1.13	1.14	0.84	0.94
3	1.21	0.76	0.99	0.91	0.83	0.99
4	0.03	0.04	0.06	0.03	0.03	0.04
5	0.84	0.87	0.93	0.56	0.76	0.89
6	0.91	0.58	0.79	0.71	0.58	0.63
7	0.55	0.67	0.59	0.57	0.63	0.58
8	1.00	0.96	1.07	0.66	0.79	0.83
9	1.17	1.49	0.79	0.89	1.09	1.20
10	0.16	0.17	0.20	0.19	0.19	0.20
11	1.12	1.06	0.99	0.92	0.95	0.99
12	0.56	0.62	0.63	0.63	0.64	0.50
Prom.	0.73	0.71	0.70	0.63	0.63	0.67

TABLA 4
Errores de Prueba (Criterio 1) [%]

Grupo Núm	Número de Elementos en Capa Interna					
	5	6	7	8	9	10
1	6.23	6.06	6.33	5.73	6.14	6.04
2	5.29	5.56	5.76	5.61	4.81	4.65
3	2.89	2.86	2.54	3.08	3.12	2.57
4	0.11	0.18	0.18	0.21	0.15	0.13
5	2.99	3.29	3.09	3.55	3.39	2.97
6	1.95	1.72	1.71	2.02	1.80	1.69
7	5.93	6.24	6.76	6.97	5.99	6.47
8	4.55	4.00	4.25	3.60	4.13	4.12
9	2.16	2.04	1.98	1.67	1.75	1.89
10	0.66	0.60	0.69	0.64	0.71	0.73
11	2.00	1.95	1.64	1.90	1.83	1.98
12	2.34	2.61	2.42	2.20	2.33	2.21
Prom.	3.09	3.09	3.11	3.10	3.01	2.95

Los patrones de prueba se localizan en las zonas que corresponden a los grupos 7,8,10,11,12,14,15 y 16, de la Fig. 3, en puntos situados entre niveles de generación. La clasificación es más difícil en estas zonas que en las de baja generación, con predominio de casos estables. La mayoría de los errores de clasificación de la Tabla 5 ocurren para casos límite que separan las zonas estable e inestable.

TABLA 5
Errores de Clasificación [%]

NNCI	Entrenamiento			Prueba		
	F. A.	F.E.E.	T.	F. A.	F.E.E.	T.
1	0.52	0.44	0.96	3.1	1.6	4.7
2	0.38	0.48	0.87	2.7	1.7	4.5
3	0.38	0.43	0.81	3.1	1.7	4.8
4	0.38	0.33	0.72	2.6	1.7	4.3
5	0.33	0.33	0.67	2.8	1.8	4.6
6	0.24	0.30	0.54	2.6	1.8	4.4
7	0.31	0.26	0.57	2.7	1.7	4.4
8	0.15	0.24	0.39	2.5	1.7	4.2
9	0.26	0.17	0.42	2.6	1.7	4.3
10	0.26	0.22	0.48	2.5	1.6	4.1

A. Resultados Utilizando Criterio 1

Se realizaron pruebas variando el número de elementos en la capa oculta desde 1 a 10. Los mejores resultados se obtuvieron para redes con más de 4 elementos en la capa oculta. En la Tabla 3 se reportan los valores alcanzados por la suma cuadrática de error de entrenamiento para estas redes. El error promedio para todas las redes se indica en el último renglón. Las redes con ocho y nueve elementos en la capa interna obtienen el mínimo error promedio.

El error máximo es de 1.49% para la red del grupo nueve, con seis elemento en la capa interna, mientras que el mínimo error, 0.03%, se obtiene en las redes de 5,8 y 9 elementos en la capa interna a las que se presentan los patrones del grupo cuatro. La Tabla 4 muestra la suma cuadrática de errores para la etapa de prueba. En este caso, el mínimo error promedio se obtiene por las redes con 10 elementos en la capa interna.

La Tabla 5 muestra el porcentaje de errores de clasificación para SBC's de 12 redes con el mismo número de neuronas en la capa interna (NNCI). El total de patrones de entrenamiento y prueba para cada SBC es de 5400 y 1056 respectivamente. F.A. indica falsa alarma o sea caso estable clasificado como inestable, F.E.E. indica falso estado estable o sea caso inestable clasificado como estable, T es el total de errores.

TABLA 3
Errores de Entrenamiento (Criterio 1) [%]

Grupo Núm	Número de Elementos en Capa Interna					
	5	6	7	8	9	10
1	0.30	0.29	0.23	0.29	0.22	0.26
2	0.96	1.02	1.13	1.14	0.84	0.94
3	1.21	0.76	0.99	0.91	0.83	0.99
4	0.03	0.04	0.06	0.03	0.03	0.04
5	0.84	0.87	0.93	0.56	0.76	0.89
6	0.91	0.58	0.79	0.71	0.58	0.63
7	0.55	0.67	0.59	0.57	0.63	0.58
8	1.00	0.96	1.07	0.66	0.79	0.83
9	1.17	1.49	0.79	0.89	1.09	1.20
10	0.16	0.17	0.20	0.19	0.19	0.20
11	1.12	1.06	0.99	0.92	0.95	0.99
12	0.56	0.62	0.63	0.63	0.64	0.50
Prom.	0.73	0.71	0.70	0.63	0.63	0.67

TABLA 4
Errores de Prueba (Criterio 1) [%]

Grupo Núm	Número de Elementos en Capa Interna					
	5	6	7	8	9	10
1	6.23	6.06	6.33	5.73	6.14	6.04
2	5.29	5.56	5.76	5.61	4.81	4.65
3	2.89	2.86	2.54	3.08	3.12	2.57
4	0.11	0.18	0.18	0.21	0.15	0.13
5	2.99	3.29	3.09	3.55	3.39	2.97
6	1.95	1.72	1.71	2.02	1.80	1.69
7	5.93	6.24	6.76	6.97	5.99	6.47
8	4.55	4.00	4.25	3.60	4.13	4.12
9	2.16	2.04	1.98	1.67	1.75	1.89
10	0.66	0.60	0.69	0.64	0.71	0.73
11	2.00	1.95	1.64	1.90	1.83	1.98
12	2.34	2.61	2.42	2.20	2.33	2.21
Prom.	3.09	3.09	3.11	3.10	3.01	2.95

Los patrones de prueba se localizan en las zonas que corresponden a los grupos 7,8,10,11,12,14,15 y 16, de la Fig. 3, en puntos situados entre niveles de generación. La clasificación es más difícil en estas zonas que en las de baja generación, con predominio de casos estables. La mayoría de los errores de clasificación de la Tabla 5 ocurren para casos límite que separan las zonas estable e inestable.

TABLA 5
Errores de Clasificación [%]

NNCI	Entrenamiento			Prueba		
	F. A.	F.E.E.	T.	F. A.	F.E.E.	T.
1	0.52	0.44	0.96	3.1	1.6	4.7
2	0.38	0.48	0.87	2.7	1.7	4.5
3	0.38	0.43	0.81	3.1	1.7	4.8
4	0.38	0.33	0.72	2.6	1.7	4.3
5	0.33	0.33	0.67	2.8	1.8	4.6
6	0.24	0.30	0.54	2.6	1.8	4.4
7	0.31	0.26	0.57	2.7	1.7	4.4
8	0.15	0.24	0.39	2.5	1.7	4.2
9	0.26	0.17	0.42	2.6	1.7	4.3
10	0.26	0.22	0.48	2.5	1.6	4.1

se emplea el disparo automático de generación (DAG), para prevenir la pérdida de estabilidad de la planta.

La inclusión del efecto de controles discretos, utilizando la metodología de RNA's se puede realizar por medio del entrenamiento de un grupo independiente de redes que consideren esta condición, sin cambiar las variables de entrada, o modificando las redes originales para que incluyan variables de entrada adicionales que describan la activación del esquema. En este caso se empleó la primera alternativa, por lo que se requiere entrenar otro grupo de RNA's para obtener la modificación de las zonas de estabilidad al entrar en operación los diferentes esquemas de protección.

La Fig. 4 muestra esquemáticamente el CDS implementado. La lógica del esquema disparará la unidad U1 o U3, al cumplirse ciertas condiciones prefijadas, como la pérdida de las líneas en 400 kV, al exceder un umbral de generación.




Fig. 4 Esquema del DAG para la planta Rio Escondido.

En este caso se entrenaron cuatro RNA's, considerando el criterio 1 para falla trifásica en REC-400. La Tabla 8 muestra los porcentajes de error de entrenamiento y la Tabla 9 los porcentajes de error de prueba. En los grupos 1 y 2 de las Tablas 8 y 9 se incluyen casos donde el DAG dispara la unidad U1, los grupos 3 y 4 corresponden a casos de activación del DAG sobre la unidad U3.

VI. EJEMPLO DE APLICACION

Los desplegados gráficos del SBC consisten de esquemas denominados espacios de generación, en los que se muestran los posibles puntos de operación, con respecto a la potencia generada por la planta, y se identifica la estabilidad o inestabilidad del punto con respecto a una falla seleccionada. En el ejemplo se supone que la planta opera con 4 unidades, con una carga cercana a la demanda

TABLE 8
Errores de Entrenamiento (DAG, Crit. 1) [%]

GRUPO	Número de Elementos en Capa Interna					
	5	6	7	8	9	10
1	1.26	0.73	0.86	0.77	0.79	1.02
2	1.06	1.07	1.02	1.05	0.85	0.86
3	1.10	0.94	0.69	0.83	0.89	0.79
4	1.11	0.99	1.07	0.73	0.93	0.99

TABLE 9
Errores de Prueba (DAG, Crit. 1) [%]

GRUPO Núm	Número de Elementos en Capa Interna					
	5	6	7	8	9	10
1	5.89	3.51	3.96	4.37	4.15	4.18
2	7.09	5.39	6.99	5.65	5.42	5.40
3	6.20	6.28	6.18	6.48	6.56	6.19
4	6.05	5.56	5.43	5.52	5.06	5.21

máxima y una línea de transmisión en 400 kV (REC-FRO) fuera de operación. Las redes neuronales 2 y 7 (falla trifásica en REC-400) crean el espacio de generación mostrado en la Fig. 5a. Se sabe que la operación del DAG sobre una unidad en 230 kV o en 400 kV alterará el espacio de generación. Las Fig. 5b y 5c muestran el efecto de la activación de DAG en las unidades de 230 y 400 kV. a) Sin DAG, b) DAG en U1, c) DAG en U3

Se observa que, sin activar el DAG, la máxima potencia que puede generar la planta, para el estandar de seguridad establecido, es de 800 MW, operando en cualquiera de los puntos 1 a 5 (Fig. 5.a). Si se activa el DAG para disparar la unidad U1, es posible aumentar en 100 MW la generación, manteniendo el sincronismo y operando en los puntos 3 o 4 (Fig. 5.b).

Si el DAG se activa para disparar la unidad U3, se obtiene el espacio de generación de la Fig. 5.c, donde los puntos 3,4 y 5 son alternativas de operación segura sin riesgo de inestabilidad.

VII. CONCLUSIONES

- o Los resultados obtenidos favorecen las posibilidades de aplicar la metodología de RNA's al problema de estimación del nivel de nivel de seguridad transitoria en sistemas longitudinales.

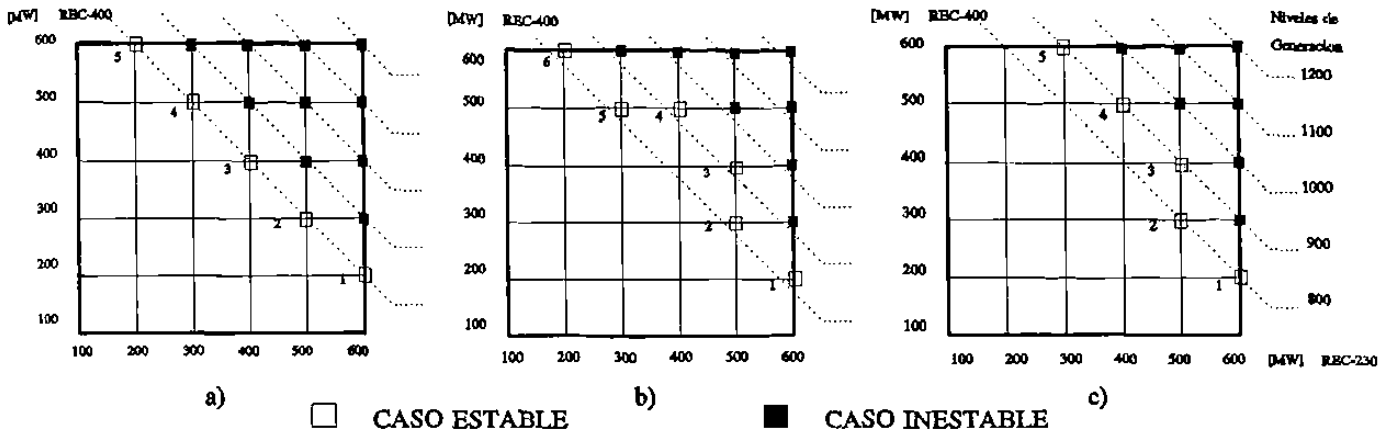


Fig. 5 Espacios de Generación. a) Sin DAG, b) DAG en U1, c) DAG en U3.

- o De las alternativas estudiadas, se concluye que la mejor estrategia de presentación de los patrones de entrenamiento es por tipo de falla y nivel de voltaje.
- o Entre las arquitecturas probadas, la que ofrece mejores resultados es la de una capa interna, con un elemento binario de salida.
- o Para incrementar la definición de la respuesta de las RNA's, es necesario proporcionar más casos cercanos a la frontera de separación de las zonas estable e inestable.
- o Es posible extender el método para incluir los efectos de controles discretos sin cambiar la formulación del problema, incluyendo nuevas RNA's especializadas en estos casos.
- o La presentación de resultados en forma de espacios de generación permite visualizar el efecto de cambios de generación y de controles suplementarios sobre las fronteras de estabilidad.

REFERENCIAS

- [1] N. Balu et al, "On Line Power System Security Analysis," *Proceedings of the IEEE*, Vol. 80, No. 2, Feb. 1992.
- [2] C. Pottle, R.J. Thomas, S. Gruber, "Rapid Analysis of Transient Stability. Computer Hardware Solutions," *IEEE Symposium on Rapid Analysis of Transient Stability*, publication No. 87TH0169-3-PWR, pp. 24-29.
- [3] A.A. Fouad, "Applications of Transient Energy Functions to Practical Power System Problems," *Idem*, pp. 8-15.
- [4] Y. Akimoto, H. Tanaka, J. Yoshizawa, D.B. Klapper, W.W. Price, K.A. Wirgau, "Transient Stability Expert System," *IEEE Transactions on Power Systems*, Vol. 4, No. 1, pp. 312-320, February 1989.
- [5] L. Wehenkel, Th. Van Cutsem, M. Ribbens-Pavella, "An Artificial Intelligence Framework for on-line Transient Stability Assessment of Power Systems," *IEEE Transactions on Power Systems*, Vol. 4, No. 2, pp. 789-800, May 1989.
- [6] R.D. Christie, S.N. Talukdar, J.C. Nixon, "CQR: A Hybrid Expert System for Security Assessment," *IEEE Transactions on Power Systems*, Vol. 5, No. 4, pp. 1503-1509, November 1990.
- [7] A.A. Fouad, S. Venkataraman, J.A. Davis, "An Expert System for Security Trend Analysis of a Stability-Limited Power System," in *IEEE/PES 1991 Winter Meeting*, February 1991.
- [8] L. Wehenkel, M. Pavella, E. Euxibie, B. Heilbronn, "Decision Tree Based Transient Stability Method. A Case Study," *IEEE Transactions on Power Systems*, Vol. 9, No. 1, pp. 459-469, February 1994.
- [9] F.S. Prabhakara, G.T. Heydt, "Review of Pattern Recognition Methods for Rapid Analysis of Transient Stability," *IEEE Symposium on Rapid Analysis of Transient Stability*, publication No. 87TH0169-3-PWR, pp. 16-23.
- [10] C.K. Pang, F.S. Prabhakara, A.H. El-Abiad, A.J. Koivo, "Security Evaluation in Power Systems Using Pattern Recognition," *IEEE Transactions on Power Systems*, Vol. PAS 93, pp. 969-976, May/June 1974.
- [11] D.R. Ostojic, G.T. Heydt, "Transient Stability Assessment by Pattern Recognition in the Frequency Domain," *IEEE Transactions on Power Systems*, Vol. 6, pp. 231-237, February 1991.
- [12] J.L. Souflis, A.V. Machias, B.C. Papadias, "An Application of Fuzzy Concepts to Transient Stability Evaluation," *IEEE Transactions on Power Systems*, Vol. 4, No. 3, pp. 1003-1009, August 1989.

- [13] F.F. Wu, Yu-Kun Tsai, Yi-Xin Yu, "Probabilistic Steady-State and Dynamic Security Assessment," *IEEE Transactions on Power Systems*, Vol. 3, No. 1, pp. 1-9, February 1988.
- [14] D.J. Sobajic, Yoh-Han Pao, "Artificial Neural-Net based Dynamic Security Assessment for Electric Power Systems," *IEEE Transactions on Power Systems*, Vol. 4, No. 1, Feb. 1989.
- [15] Yoh-Han Pao, D.J. Sobajic, "Combined use of Unsupervised and Supervised Learning for Dynamic Security Assessment," *IEEE Transactions on Power Systems*, Vol. 7, No. 2, May 1992.
- [16] M. Aggoune, M.A. El-Sharkawi, D.C. Park, R.J. Marks III, "Preliminary Results on Using Artificial Neural Networks for Security Assessment," *IEEE Transactions on Power Systems*, Vol. 6, No. 2, May 1991.
- [17] V. Miranda, J.N. Fidalgo, J.A. Peças Lopes, L.B. Almeida, "Real Time Preventive Actions for Transient Stability Enhancement with a Hybrid Neural Network - Optimization Approach," paper 94SM517-3 PWRS presented at *IEEE-PES 1994 Summer Meeting*, July 1994.
- [18] K. Fukunaga, *Introduction to Statistical Pattern Recognition*, 2nd Ed., Academic Press, Inc., 1990, Chapters 9, 10.
- [19] T.P. Vogl, J.K. Mangis, A.K. Rigler, W.T. Zink, D.L. Alkon, "Accelerating the convergence of the backpropagation method," *Biological Cybernetics*, vol. 59, pp. 257-263, 1988.

Dr. Florencio Aboytes García. Ingeniero Mecánico Electricista y Maestro en Ciencias del Instituto Tecnológico y de Estudios Superiores de Monterrey en 1968 y 1969. Doctorado en Ingeniería Eléctrica en el Imperial College of Science and Technology de Londres, Inglaterra en 1974. Desde 1975 trabaja en Comisión Federal de Electricidad donde ha ocupado diversos puestos técnicos en la Gerencia de Estudios y la Gerencia del Centro Nacional de Control de Energía (CENACE). Actualmente es Jefe de la Unidad de Ingeniería Avanzada del CENACE.

Adicionalmente desde 1975 ha impartido cursos de postgrado y dirigido trabajos de investigación en la Sección de Graduados de ESIME-IPN, la División de Estudios de Postgrado de la UNAM, y en el Programa de Doctorado de la Facultad de Ingeniería Mecánica y Eléctrica de la UANL. Actualmente es Presidente del Comité Doctoral de FIME-UANL.

Es Senior Member del IEEE, miembro de CIGRE y forma parte del Sistema Nacional de Investigadores desde 1985.

M.C. Rogelio Ramírez Barradas. Obtuvo la licenciatura en Ingeniería Eléctrica por el Instituto Politécnico Nacional en 1984 y la Maestría en Ciencias por la Universidad Autónoma de Nuevo León en 1989. Desde 1984 labora en el Centro Nacional de Control de Energía de CFE, estando actualmente comisionado al Programa Doctoral en Ingeniería Eléctrica en Monterrey, N.L.

Sus principales áreas de interés son la operación de Sistemas Eléctricos de Potencia, los Sistemas Expertos y las Redes Neuronales.

