



UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO

PROGRAMA DE MAESTRÍA Y DOCTORADO EN INGENIERÍA
FACULTAD DE INGENIERÍA

**Metodología para la Optimización de
Combustible de Reactores Nucleares
Avanzados de Agua en Ebullición**

T E S I S
QUE PARA OPTAR POR EL GRADO DE:

MAESTRO EN INGENIERÍA
Energía – Sistemas Energéticos

P R E S E N T A:

ROBERTO CARMONA HERNÁNDEZ

Tutora

DRA. CECILIA MARTÍN DEL CAMPO MÁRQUEZ



Ciudad Universitaria, México D. F. 2008

JURADO ASIGNADO:

Presidente: Dr. Juan Luis Francois Lacouture, FI-UNAM

Secretario: Dra. Cecilia Martín del Campo Márquez, FI-UNAM

Vocal: Dr. Juan José Ortiz Servin, ININ

1er. Suplente: M. en C. José Luis Montes Tadeo, ININ

2do. Suplente: M. en C. Edgar Salazar Salazar, FI-UNAM

Lugar o lugares donde se realizó la tesis:

Posgrado de la Facultad de Ingeniería, UNAM

TUTOR DE TESIS:

Dra. Cecilia Martín del Campo Márquez, FI-UNAM

FIRMA

Agradecimientos

A Ivonne por su continua motivación y confianza absoluta. No pasa un día en el que no valore y agradezca lo que haces por mí.

A mi familia por su incondicional apoyo.

A la Dra. Cecilia Martín del Campo y al Dr. Juan Luis François por su guía y dirección.

A todos aquellos que participaron de manera directa o indirecta en la realización de este trabajo: mis amigos y maestros de la maestría, en especial al Grupo de Ingeniería Nuclear de la Facultad de Ingeniería.

A la Facultad de Ingeniería de la Universidad Nacional Autónoma de México.

Al Programa de Apoyo a Proyectos de Investigación e Innovación Tecnológica (PAPIIT) de la Universidad Nacional Autónoma de México, Proyecto IN104007, por el apoyo para la realización de este trabajo.

Al CONACYT por la beca recibida durante mis estudios de maestría y por el proyecto CONACYT - 54583 "Desarrollo de Modelos de Física de Reactores para el Diseño y Optimización de Combustible de Reactores Nucleares Avanzados".

Rodrigo:

Todo lo que hago es para tí.

Índice

Índice	ix
Índice de Figuras	xii
Índice de Tablas	xiv
Resumen	xv
Introducción	xvii
Acrónimos	xix
1. Reactores de Agua en Ebullición	1
Resumen del capítulo	1
1.1 Descripción del BWR	3
1.1.1 El Ensemble de la Vasija del BWR	4
1.1.2 Sistema de Limpieza de Agua del Reactor (RWCUS)	7
1.1.3 Remoción de Calor Residual (RHR)	8
1.1.4 Sistema de Refrigeración del Núcleo Aislado (RCIC)	9
1.1.5 Sistema de Control de Líquido de Reserva (SLCS)	10
1.1.6 Sistemas de Refrigeración de Emergencia del Núcleo (ECCS)	11
1.1.6.1 Sistemas de Emergencia de Enfriamiento del Núcleo a Alta Presión	11
1.1.6.1.1 Sistema de Inyección de Refrigerante a Alta Presión (HPCI)	11
1.1.6.1.2 Sistema de Despresurización Automática (ADS)	11
1.1.6.2 Sistemas de Emergencia de Enfriamiento del Núcleo a Baja Presión	12
1.1.6.2.1 El Sistema de Rocío del Núcleo (RCS)	12
1.1.6.2.2 El Modo de Inyección de Refrigerante a Baja Presión del Sistema de Remoción de Calor Residual (LPCI del RHR)	12
1.1.7 Tipos de Contención de los BWRs	14
1.1.7.1 MARK I	14
1.1.7.2 MARK II	15
1.1.7.3 MARK III	16
1.2 Evolución del BWR hacia el Reactor ABWR	17
1.2.1 Simplificación de la Vasija	18
1.2.2 Rediseño de la Contención	18
1.2.3 Redundancia de los Sistemas	19
1.3 El Reactor Avanzado de Agua en Ebullición	19
1.3.1 La Vasija del Reactor	19
1.3.2 El Núcleo del Reactor	21
1.3.2.1 Ensemble de Combustible	22
2. Administración del combustible dentro del núcleo	25
Resumen del capítulo	25
2.1 Objetivo de la Administración de Combustible dentro del Núcleo	27
2.2 Actividades de Diseño de Recargas	30
2.2.1 Diseño del Ensemble Combustible	30
2.2.2 Diseño de Patrones de Recargas	30

2.2.3 Diseño de Patrón de Barras de Control (PBC)	31
2.3 Variables Importantes a Considerar en el Diseño de Combustible	31
3. Algoritmos Genéticos	33
Resumen del capítulo	33
3.1 Representación Genética de las Soluciones	37
3.2 Creación de la Población Inicial	37
3.3 Función de Evaluación o Función de Adaptabilidad (Fitness)	38
3.4 Soluciones Factibles y no Factibles: Manejo de las Restricciones del Problema	38
3.5 Mecanismos de Selección de Padres	39
3.5.1 Métodos de Selección Proporcional	40
3.5.1.1 Método de la Ruleta	40
3.5.1.2 Selección Universal Estocástica	40
3.5.2 Método de Selección por Jerarquías	41
3.5.2.1 Selección Mediante Torneo	41
3.6 Operadores Genéticos	42
3.6.1 Operador de Cruzamiento	42
3.6.1.1 Cruzamiento de un Punto	43
3.6.1.2 Cruzamiento de dos o más Puntos	44
3.6.1.3 Cruzamiento Uniforme	44
3.6.1.4 Sesgos del Cruzamiento	45
3.6.1.5 Variantes del Cruzamiento	46
3.6.1.6 Comportamiento Deseable del Cruzamiento	46
3.6.2 Mutación	47
3.6.3 Cruzamiento Vs. Mutación	48
3.7 Elitismo	48
3.8 Modelos de Población	49
3.8.1 Modelo Global (Panmítico)	49
3.8.2 Modelo Regional	49
3.8.3 Modelo de Difusión Local o de Vecindades	51
3.8.4 Reinserción	51
3.8.4.1 Reinserción Global	52
3.8.4.2 Reinserción Local	52
3.9 Parámetros de los Algoritmos Evolutivos	53
3.10 Ventajas de los Algoritmos Genéticos	53
3.11 Limitaciones de los Algoritmos Genéticos	56
4. Aplicación de los algoritmos genéticos	59
Resumen del capítulo	59
4.1 Simulador Neutrónico CASMO-4	61
4.2 Representación de la solución	61
4.2.1 Composiciones de Combustible en la Celda	62
4.2.2 Reglas Heurísticas	63

4.3. Modelo Matemático de la Función Objetivo	64
4.4. Aplicación del Algoritmo Genético	65
5. Resultados	69
Resumen del capítulo	69
CASO 1	71
CASO 2	78
6. Conclusiones	87
Acrónimos	91
Bibliografía	93

Índice de Figuras

Figura 1.1. Diagrama de una Central Tipo BWR	3
Figura 1.2. Vasija del Reactor	5
Figura 1.3. Esquema de la Celda de Control de un BWR	6
Figura 1.4. Esquema del Sistema de Limpieza de Agua del Reactor	7
Figura 1.5. Esquema del Sistema de Remoción de Calor Residual	8
Figura 1.6. Esquema del Sistema de Refrigeración del Núcleo Aislado	9
Figura 1.7. Esquema del Sistema de Control de Líquido de Reserva	10
Figura 1.8. Esquema de los Sistemas de Emergencia de Enfriamiento del Núcleo a Alta Presión	12
Figura 1.9. Esquema de Los Sistemas de Emergencia de Enfriamiento del Núcleo a Baja Presión	13
Figura 1.10. Esquema del MARK I	14
Figura 1.11. Esquema del MARK II	15
Figura 1.12. Esquema del MARK III	16
Figura 1.13. Esquema de un ABWR	17
Figura 1.14. Eliminación de Lazos Externos	18
Figura 1.15. Vasija del Reactor ABWR	20
Figura 1.16. Configuración del Núcleo del Reactor Tipo ABWR	21
Figura 1.17. Esquema de un Ensamble de Combustible	22
Figura 2.1. Proceso Global De Optimización Iterativo	28
Figura 2.2. Sección radial de una celda de combustible	28
Figura 2.3. Ejemplo de una descripción axial de un ensamble combustible	29
Figura 3.1. Esquema de Funcionamiento de un Algoritmo Evolutivo	35
Figura 3.2. Cruzamiento en un Punto	43
Figura 3.3. Cruzamiento de dos o mas Puntos	44
Figura 3.4. Cruzamiento Uniforme	45
Figura 3.5. Operador Mutación	47
Figura 3.6. Topología de Migración Irrestriccta	50
Figura 3.7. Topología de Migración de Anillo Distancia 1	50
Figura 3.8. Topología de Migración entre Vecindades (en este caso: Malla de 2 Dimensiones)	50
Figura 4.1. Sección Radial de una Celda de Combustible 10x10	62
Figura 4.2. Representación Esquemática de la Celda de Combustible con Simetría Diagonal	62
Figura 4.3. Diagrama de flujo de la aplicación del Algoritmo Genético	66
Figura 5.1. Evolución del Enriquecimiento para los Individuos dentro de la Generación (Caso 1)	72
Figura 5.2. Evolución de k_{inf} para los Individuos dentro de la Generación (Caso 1)	72

Figura 5.3. Evolución del PPF de los Individuos dentro de la Generación (Caso 1)	73
Figura 5.4. Evolución de la Calificación de los Individuos dentro de la Generación (Caso 1)	73
Figura 5.5. Mapa del Mejor Individuo (Caso 1)	74
Figura 5.6 Espacio de Búsqueda para el Parámetro de k_{inf} (Caso 1)	75
Figura 5.7 Espacio de Búsqueda para el Parámetro de PPF (Caso 1)	76
Figura 5.8. Comparación de las Curvas de k -infinita en Función del Quemado (Caso 1)	76
Figura 5.9 Comparación de las Curvas de PPF en Función del Quemado (Caso 1)	77
Figura 5.10. Curva de k -infinita en Función del Quemado para el Mejor Individuo a Diferentes Vacíos (Caso 1)	77
Figura 5.11. Curva de PPF en Función del Quemado para el Mejor Individuo a Diferentes Vacíos (Caso 1)	78
Figura 5.12. Evolución del Enriquecimiento para los Individuos dentro de la Generación (Caso2)	79
Figura 5.13. Evolución de k_{inf} para los Individuos dentro de la Generación (Caso2)	79
Figura 5.14. Evolución del PPF de los Individuos dentro de la Generación (Caso 2)	80
Figura 5.15. Evolución de la Calificación de los Individuos dentro de la Generación (Caso 2)	80
Figura 5.16. Curva de k -infinita en Función del Quemado para el Mejor Individuo (Caso 2)	82
Figura 5.17. Curva de PPF en Función del Quemado para el Mejor Individuo (Caso 2)	82
Figura 5.18. Curva de k -infinita en Función del Quemado para el Mejor Individuo a Diferentes Fracciones de Vacío (Caso 2)	83
Figura 5.19 Curva de PPF en Función del Quemado para el Mejor Individuo a Diferentes Fracciones de Vacío (Caso 2)	83
Figura 5.20. Gráfica de Calificación de la Ejecución 20040_0207080026 (Caso 1)	84
Figura 5. 21. Gráfica de Calificación de Otra Ejecución (Caso 1)	84
Figura 5.22. Evolución de k -inf con el Quemado obtenida con CASMO y HELIOS	85
Figura 5.23. Evolución de PPF con el Quemado Obtenida con CASMO y HELIOS	85

Índice de Tablas

Tabla 1.1. Comparación entre el Diseño GE14 y GE12	22
Tabla 1.2. Datos Técnicos de un ABWR	23
Tabla 4.1. Enriquecimientos y Concentraciones de Gadolinia en las Composiciones	63
Tabla 4.2. Definición de Términos en el Modelo Matemático de la Función Objetivo	64
Tabla 5.1. Valores de los Pesos que Intervienen en la Función Objetivo	71
Tabla 5.2. Parámetros del Algoritmo Genético en la Ejecución	71
Tabla 5.3. Valores Objetivo y Valores Límite para los Parámetros (Caso 1)	71
Tabla 5.4. Valores de los Parámetros del Mejor Individuo (Caso 1)	74
Tabla 5.5. Comparación de los Parámetros del Mejor Individuo y la Celda de Referencia (Caso 1)	74
Tabla 5.6. Valores de los Parámetros de la Última Generación	75
Tabla 5.7. Valores Objetivo y Valores Límite para los Parámetros (Caso 2)	78
Tabla 5.8. Valores de los Parámetros del Mejor Individuo (Caso 2)	81
Tabla 5.9. Comparación de los Parámetros del Mejor Individuo y la Celda de Referencia (Caso 2)	81
Tabla 5.10. Valores de los Parámetros de la Última Generación	81

Resumen

Para los reactores de agua en ebullición la administración del combustible dentro del núcleo juega un papel muy importante, ya que el diseño radial y axial de las celdas de combustible, el diseño del patrón de barras de control y el diseño de los patrones de recarga afectan el control, la operabilidad, la economía y la eficiencia de una central nuclear. El diseño radial involucra la distribución y el acomodo de diferentes composiciones de combustible y veneno quemable con el fin de tener un perfil de potencia uniforme y un mejor quemado del combustible.

El problema de la distribución radial de combustible es un problema de optimización del tipo combinatorio que puede ser resuelto con el uso de métodos de optimización meta-heurísticos. En este trabajo se presenta el uso de Algoritmos Genéticos para la solución de este problema. Esta técnica está inspirada en la evolución de las especies en cuanto a que se busca la supervivencia del individuo más apto, utilizando operadores genéticos como la selección, la cruce y la mutación. Debido a sus similitudes con el mundo natural los Algoritmos Genéticos ofrecen una buena alternativa para la solución de problemas combinatorios muy grandes ya que pueden abarcar amplios espacios de búsqueda sin estancarse en óptimos locales.

El proceso de optimización desarrollado en esta tesis se codificó en lenguaje C en el sistema operativo LINUX. Para la verificación de los resultados, el programa se ligó al simulador neutrónico CASMO-4, el cual es un código de transporte en multigrupos de simulación neutrónica de ensambles de combustible, que ha sido validado y es utilizado ampliamente para el cálculo de bancos de datos nucleares para reactores de agua en ebullición. En el código programado se automatizó la creación de las entradas al simulador, la ejecución del simulador CASMO-4 y la obtención de los parámetros que intervienen en la función objetivo a partir de la salida del simulador. Se aplicó al diseño de una celda de combustible de tipo 10x10.

A pesar de los avances tecnológicos en los reactores de agua en ebullición, la parte del núcleo y el combustible se ha mantenido relativamente similar por lo que el diseño de combustible puede aplicarse con mínimas modificaciones a los diferentes tipos de reactores de agua en ebullición, incluyendo los diseños avanzados.

Introducción

En México se cuenta con dos reactores de agua en ebullición que han operado exitosamente y tomando en cuenta la prospectiva de demanda de energía eléctrica a largo plazo y los costos de generación eléctrica de las diferentes tecnologías, es probable que se construyan nuevas centrales nucleares.

El avance tecnológico constante ha cambiado la manera en la que se genera electricidad mediante energía nuclear. Estos cambios se ven reflejados tanto en nuevos diseños de reactores nucleares como en actualizaciones de los diseños ya existentes. Los avances se traducen en mayor seguridad, mayor capacidad de generación y en un uso más eficiente del combustible.

Este estudio contribuye al mejor entendimiento de los reactores avanzados, ya que se tiene por objetivo desarrollar una metodología para la optimización neutrónica de combustible para el reactor ABWR (Advanced Boiling Water Reactor). Las similitudes del combustible y del núcleo entre los diferentes diseños de BWR's hace que este estudio sea aplicable en los reactores actualmente en operación y en los diseños avanzados. Además, en todos los reactores nucleares de agua en ebullición se hacen recargas de combustible periódicas las cuales deben ser diseñadas de tal forma que se optimice la utilización del combustible y se satisfagan las condiciones de operación de manera segura y confiable.

El problema de la optimización de combustible es complejo ya que incluye a la distribución radial y la distribución axial de diferentes composiciones en los ensambles combustibles y la recarga del núcleo con ensambles combustibles nuevos o que ya tienen 1, 2 ó 3 ciclos de permanencia en el núcleo. Cada uno de los problemas de optimización es un problema de tipo combinatorio que debe ser abordado por alguna técnica de optimización adecuada al problema. En este caso los algoritmos genéticos ofrecen un enfoque "natural" a los procesos de optimización mediante búsquedas inteligentes con bases heurísticas, además de ser una alternativa para la resolución de problemas que involucran discontinuidades, no linealidades, funciones no derivables, o grandes combinaciones por lo que pasan a ser una herramienta de gran utilidad.

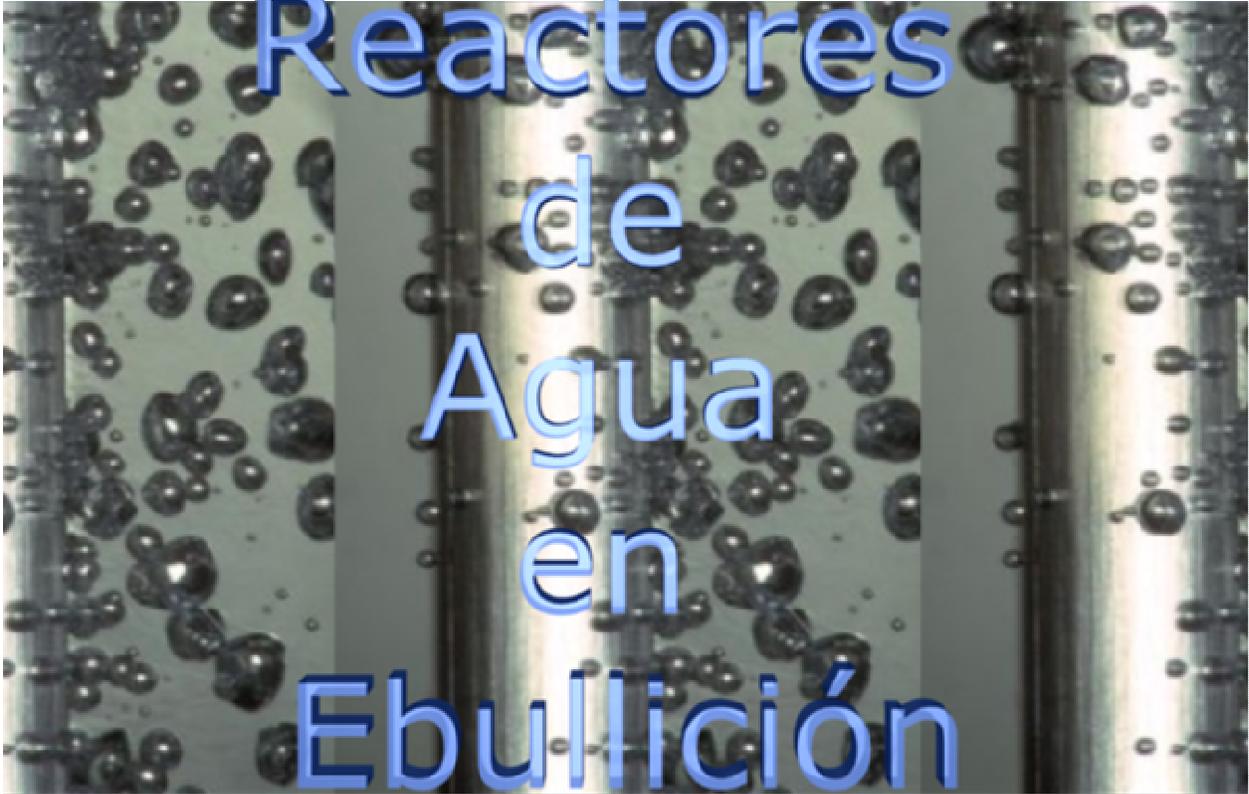
Varios estudios relacionados con la optimización de la distribución de enriquecimiento en las barras de un ensamble de combustible BWR han contribuido al entendimiento y a la solución de este problema combinatorio de alta complejidad. El método de aproximación por programación lineal (Hirano, 1996) da resultados bastante satisfactorios que producen diseños candidatos realizables comparables a aquellos elaborados por un ingeniero experto. Una metodología que combina el método de matriz de respuesta con técnicas de programación no lineal (Lym, 97) fue aplicado para buscar una distribución de enriquecimientos óptima que dé la mejor aproximación a una distribución de potencia preestablecida en un ensamble de combustible bidimensional. Otra aplicación a la optimización de distribuciones de enriquecimiento MOX (Mixed Oxide) en ensambles típicos de reactores de agua ligera usó un algoritmo basado en el método simplex (Cuevas, 2002). También se desarrolló un sistema multiobjetivo y multirestricción para la optimización de arreglos barra por barra basado en Recocido Simulado (Maldonado, 1998). Recientemente ha sido utilizado el método de optimización por búsqueda Tabú con resultados exitosos (Francois, 2003) y otro trabajo relacionado con la optimización de la colocación de veneno consumible para el caso de los reactores de agua a presión (Yilmaz, 2005). También hay varias aplicaciones de los Algoritmos Genéticos para resolver diferentes problemas dentro de las tareas de administración de combustible nuclear, estas aplicaciones han propuesto buenas ideas para implementar aplicados a la optimización de recarga para BWR's (Francois, 1999). También fueron aplicados al diseño axial de combustible de BWR's (Martín del Campo, 2001). De manera similar los AG's fueron utilizados para la optimización del diseño radial de celdas de combustible para un BWR (Martín del Campo, 2007). También

fueron usados para el diseño de recargas de combustible en PWRs (Pressurized Water Reactor) (Alim, 2004). Recientemente los AG's fueron implementados con alta eficacia este método de optimización.

Los Algoritmos Genéticos fueron como un método de optimización para la recarga del núcleo en el VVER (Reactor a Presión de Agua-Agua), el cual es la versión rusa del PWR (Guler, 2004).

En este trabajo se presenta el desarrollo de un sistema computacional, totalmente automatizado, para el diseño y optimización radial de celdas de combustible de BWRs basado en Algoritmos Genéticos.

El contenido del presente trabajo se divide en seis capítulos. En el capítulo 1 se describe la tecnología de los BWRs, así como su evolución a lo largo de los años. También se presentan el núcleo de un ABWR y su combustible. El capítulo 2 habla de manera resumida sobre las etapas de cálculo del núcleo de un reactor, esto es, las diferentes etapas del diseño de combustible dentro del núcleo. Los algoritmos genéticos como método de optimización son detallados en el capítulo 3 mientras que la aplicación del método se explica en el capítulo 4. Por último, los capítulos 5 y 6 muestran los resultados y las conclusiones respectivamente.



Reactores de Agua en Ebullición

Este capítulo describe al reactor de agua en ebullición, BWR, haciendo un análisis de sus componentes (USNRC). Una vez descritas las características del BWR, el capítulo presenta la evolución de los sistemas del BWR para concluir en la presentación del reactor avanzado de agua en ebullición ABWR (Fennern, 2007).

1.1 Descripción del BWR

El Reactor de Agua en Ebullición (Boiling Water Reactor, por sus siglas en inglés) (Figura 1.1) es un sistema de generación de vapor de ciclo directo. El combustible utilizado consiste de pastillas cerámicas compuestas de dióxido de uranio con un enriquecimiento entre el 2 y 5%.

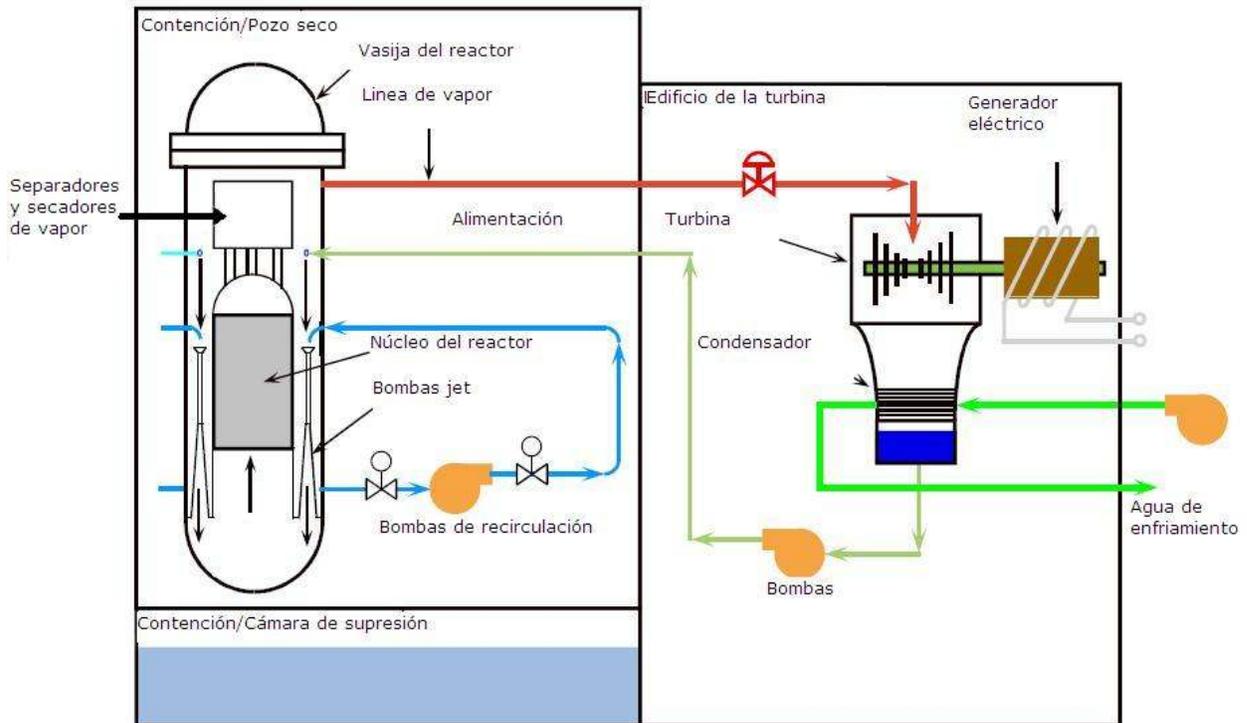


Figura 1.1. Diagrama de una Central Tipo BWR

Adentro de la vasija del BWR, el agua hierve al capturar el calor producido por las fisiones que se llevan a cabo en las barras de combustible, produciendo una mezcla de vapor y agua, cuando el agua extremadamente pura (refrigerante del reactor) se mueve hacia arriba a través del núcleo absorbiendo calor.

La mayor diferencia en la operación de un BWR con respecto a otros sistemas nucleares es la formación de vacíos de vapor en el núcleo.

La mezcla de vapor y agua deja la parte superior del núcleo y entra a las dos etapas de separación de humedad (los separadores y secadores de vapor), donde las gotas de agua son removidas antes de que al vapor se le permita entrar a la línea de vapor, éste deja la vasija del reactor con una calidad de 0.30 % de humedad y una presión entre 970 a 1000 psia para entonces dirigirse a la turbina principal haciendo que gire junto con el generador eléctrico.

El vapor que sale de la turbina pasa al condensador, donde es condensado en agua que es bombeada y regresada a la vasija del reactor, mediante una serie de bombas.

1.1.1 El Ensamble de la Vasija del BWR

El ensamble de la vasija del reactor consiste en la vasija del reactor y sus componentes internos, incluyendo las estructuras de soporte del núcleo, el envolvente del núcleo, el equipo de remoción de humedad y los ensambles de las bombas jet.

La vasija está hecha de aleación baja de acero al carbón, manganeso y molibdeno. La pared inferior del cuerpo está revestida con acero austenítico inoxidable. El interior de la tapa no está revestida ya que el ambiente al que está expuesta es menos corrosivo. Los propósitos del ensamble de la vasija del reactor son:

- Albergar al núcleo del reactor.
- Servir como parte de la barrera de presión del refrigerante del reactor.
- Soportar y alinear al combustible y las barras del control.
- Proveer de una trayectoria de flujo para la circulación del refrigerante por el combustible.
- Remover humedad del vapor que sale del núcleo.
- Proveer de un volumen inundable en caso de un accidente de pérdida de refrigerante.

El ensamble de la vasija se apoya en la falda de soporte de la vasija que está montada en el pedestal de soporte de la vasija del reactor. La vasija del reactor está montada verticalmente dentro del pozo seco y consiste de una capa cilíndrica con una cabeza inferior redonda. La cabeza superior es también de forma redonda pero es removible para facilitar las operaciones de abastecimiento de combustible.

Los componentes internos de la vasija del reactor están sostenidos por la cabeza inferior y/o la pared de la vasija. El núcleo del reactor está compuesto por ensambles de combustible, barras de control e instrumentos de monitoreo de neutrones. La estructura que rodea al núcleo activo consiste en una envolvente de núcleo, la placa del núcleo y la guía superior (Figura 1.2).

El agua entra a la vasija por medio de la penetración de entrada de agua de alimentación, se mezcla con el agua de recirculación interna y fluye al ánulo entre la pared de la vasija y la envolvente del núcleo.

Del ánulo, una porción deja la vasija vía la penetración de salida del agua de recirculación, el excedente entra en la succión de las bombas jet.

Los tres flujos se juntan en los difusores de las bombas jet y se descargan al plenum inferior del núcleo.

El agua fluye hacia la parte superior a través del núcleo donde una porción del líquido es convertida en vapor, la mezcla en dos fases pasa a través de los separadores y secadores de vapor.

El líquido separado del vapor regresa al ánulo, para reciclarse, y el vapor es enviado a la turbina.

El vapor saturado deja la vasija del reactor por medio de cuatro líneas de vapor principal, cada línea tiene dos válvulas de aislamiento, una dentro y otra afuera de la contención.

Además, cada línea de vapor cuenta con dos grupos de válvulas de seguridad-alivio (su función es reducir la presión en la vasija). El primer grupo de válvulas de seguridad actúan por sí solas dependiendo de que se alcance la presión de actuación, y el segundo grupo son

controladas de manera remota. El vapor desfogado por cualquier grupo de válvulas de alivio de seguridad es descargado en la alberca de supresión.



Figura 1.2. Vasija del Reactor

Una característica representativa de los BWRs (en sus versiones del 1 al 6) es el conjunto de la celda de control (Figura 1.3). Cada celda de control consiste de una barra de control y 4 ensamblajes combustibles que la rodean. A diferencia de los ensamblajes de combustible del PWR, el ensamblaje de combustible de un BWR está dentro de un canal de combustible que dirige el refrigerante hacia arriba a través del combustible y que actúa como superficie de soporte de la barra de control, además, protege al combustible durante las operaciones de abastecimiento.

La potencia del núcleo es regulada mediante el movimiento de las barras de control que entran por debajo de la vasija. Los componentes que ocupan el resto del interior de la vasija del reactor son:

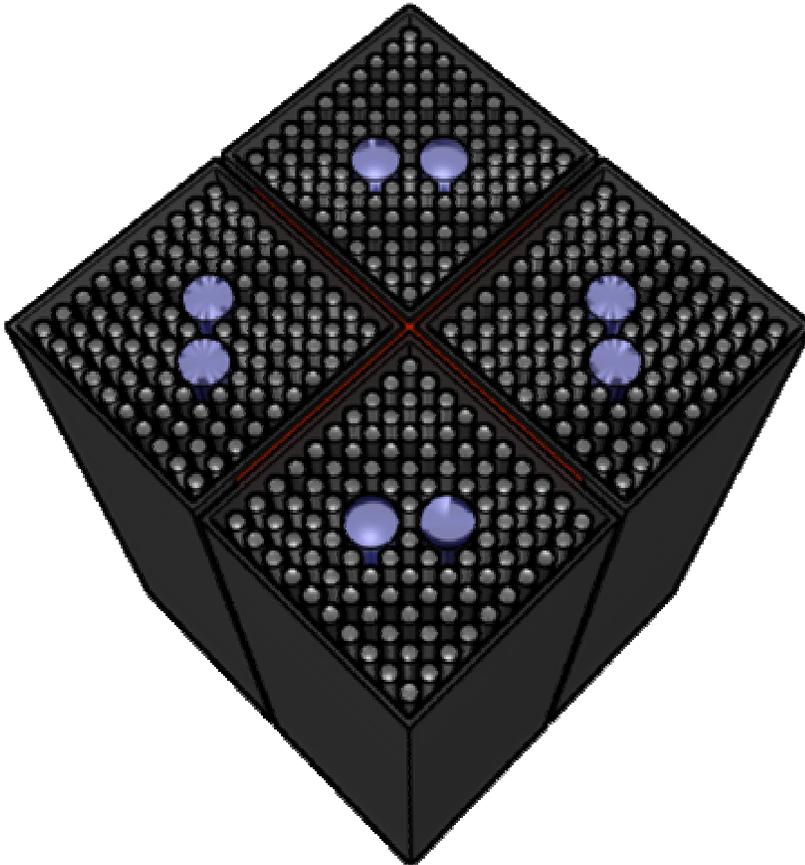


Figura 1.3. Esquema de la Celda de Control de un BWR

- Los ensambles de las bombas jet, que están sumergidos en agua, acomodados en dos grupos semicirculares de 10, recibiendo cada grupo suministro de una bomba de circulación separada.
- Separadores y secadores de vapor: se encuentran en la parte superior.
- Rociadores de agua de alimentación.
- Los rociadores del núcleo.

La vasija opera bajo las siguientes condiciones de diseño:

- Presión 1250 psig (8621 kPa)
- Temperatura 575 °F (574.82 K)

Sus dimensiones son:

- Altura 21.75 m
- Diámetro interior 6.045 m
- Espesor en la región central del cilindro 0.16 m

Sus penetraciones principales:

- 4 líneas de vapor
- 6 líneas de alimentación de agua para enfriamiento y moderación
- 3 sistemas de aspersion de alta y baja presión
- 10 entradas de recirculación
- 2 salidas de recirculación

1.1.2 Sistema de Limpieza de Agua del Reactor (RWCUS)

El propósito del RWCUS (Figura 1.4) es mantener una alta pureza en el agua del reactor mediante la remoción de productos de fisión, productos de corrosión y otras impurezas solubles e insolubles.

La bomba de limpieza de agua del reactor, toma agua del sistema de recirculación y de la cabeza inferior de la vasija y la bombea a través de intercambiadores de calor para enfriar el fluido.

Después el agua se manda a través de filtros/ desmineralizadores para su limpieza. Después de la limpieza el agua es regresada a la vasija del reactor a través de la tubería de agua de alimentación.

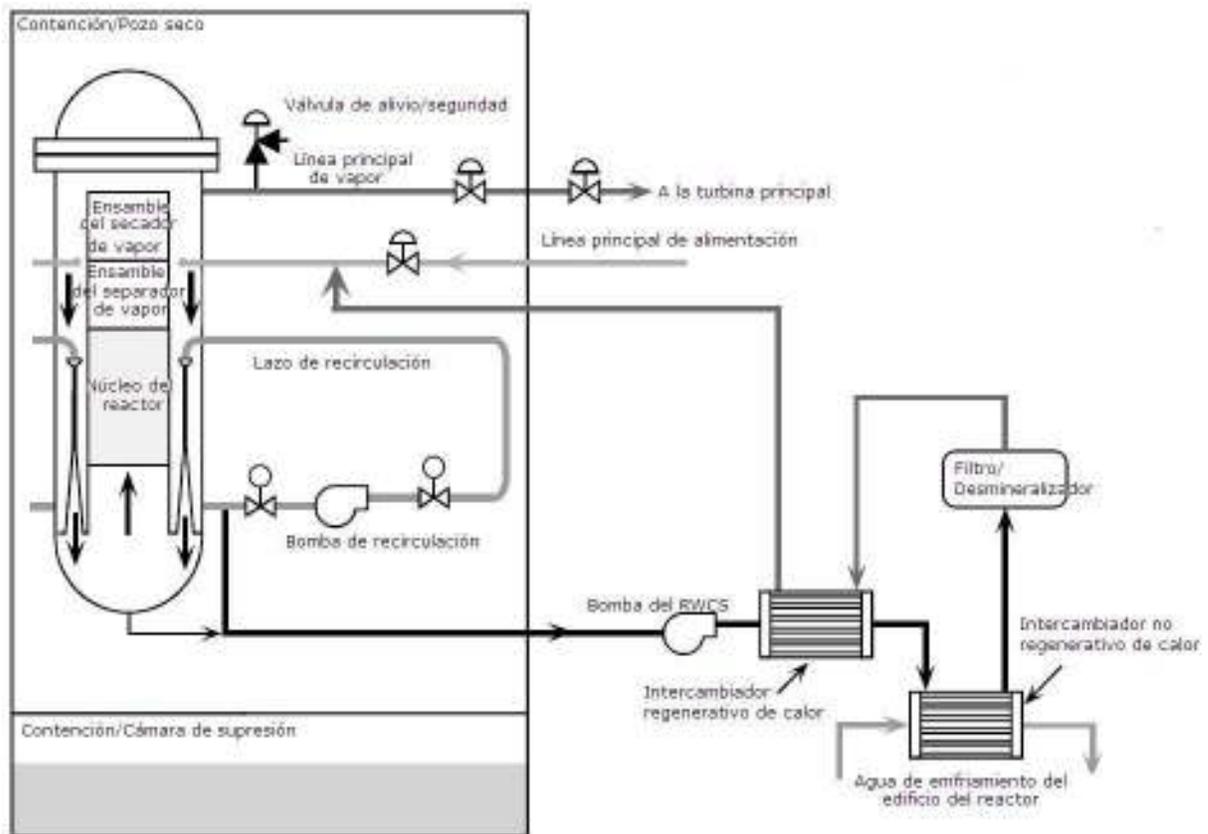


Figura 1.4. Esquema del Sistema de Limpieza de Agua del Reactor

1.1.3 Remoción de Calor Residual (RHR)

Durante la generación normal de potencia el calor es removido al producirse vapor en la vasija del reactor y luego ese vapor es usado para generar energía eléctrica.

Cuando se apaga el reactor, el núcleo continuará generando calor de decaimiento.

El modo de enfriamiento de apagado del sistema de remoción de calor residual (RHR) (Figura 1.5) es usado para completar el proceso de enfriamiento cuando la presión disminuye aproximadamente 50 psi. El agua es bombeada desde el lazo de recirculación del reactor a través del intercambiador de calor y de regreso al reactor vía el lazo de recirculación. Se usa el lazo de recirculación para limitar el número de penetraciones de la vasija del reactor.

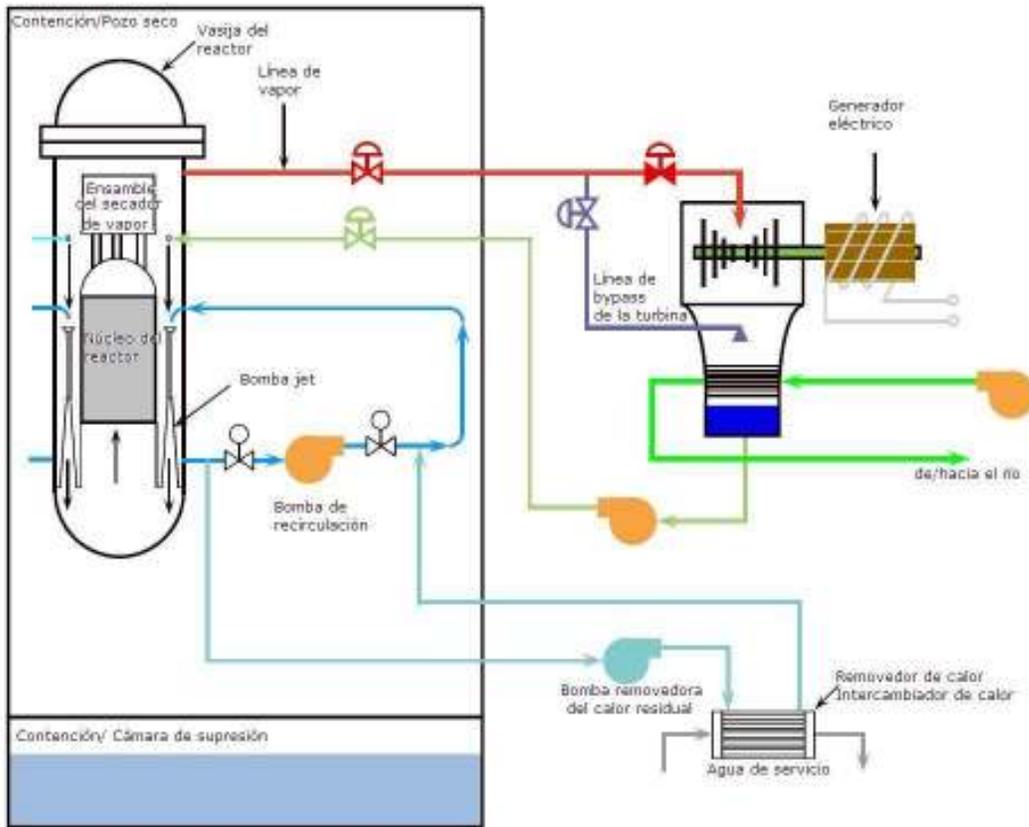


Figura 1.5. Esquema del Sistema de Remoción de Calor Residual

1.1.4 Sistema de Refrigeración del Núcleo Aislado (RCIC)

El RCIC (Figura 1.6) provee de agua de compensación a la vasija del reactor para el enfriamiento del núcleo cuando las líneas principales de vapor son aisladas y el suministro normal de agua a la vasija del reactor se pierde.

El RCIC consiste de una bomba movida por una turbina (una turbo-bomba), tuberías y válvulas necesarias para entregar agua a la vasija del reactor en condiciones de operación. La turbina es impulsada por vapor suministrado por las líneas principales de vapor. EL vapor que sale de la turbina es canalizado a la piscina de supresión.

La turbo-bomba suministra agua de compensación desde el tanque de almacenamiento de condensados (TAC), teniendo como suministro alternativo a la piscina de supresión, hasta la vasija del reactor a través de la tubería de agua de alimentación.

La tasa de flujo del sistema es aproximadamente igual a la tasa de salida del vapor 15 minutos después del apagado con el calor de decaimiento máximo de diseño.

La inicialización del sistema es automática para un nivel bajo de agua en la vasija del reactor o manual para el operador.

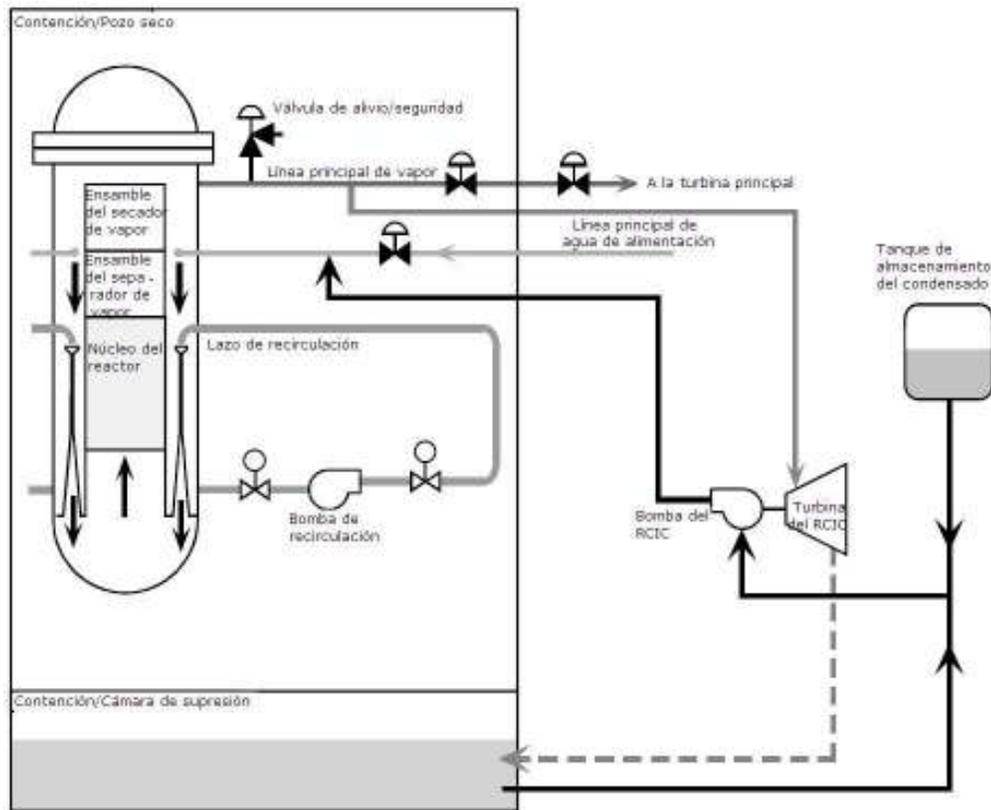


Figura 1.6. Esquema del Sistema de Refrigeración del Núcleo Aislado

1.1.5 Sistema de Control de Líquido de Reserva (SLCS)

El SLCS (Figura 1.7) inyecta un veneno de neutrones (Boro) en la vasija del reactor para detener la reacción en cadena, independientemente de las barras de control, y mantiene al reactor apagado mientras la planta es apagada a temperaturas de mantenimiento.

El SLCS consiste de un tanque de almacenamiento calentado, 2 bombas de desplazamiento positivo, 2 válvulas explosivas y la tubería necesaria para inyectar la solución absorbidora de neutrones en la vasija del reactor.

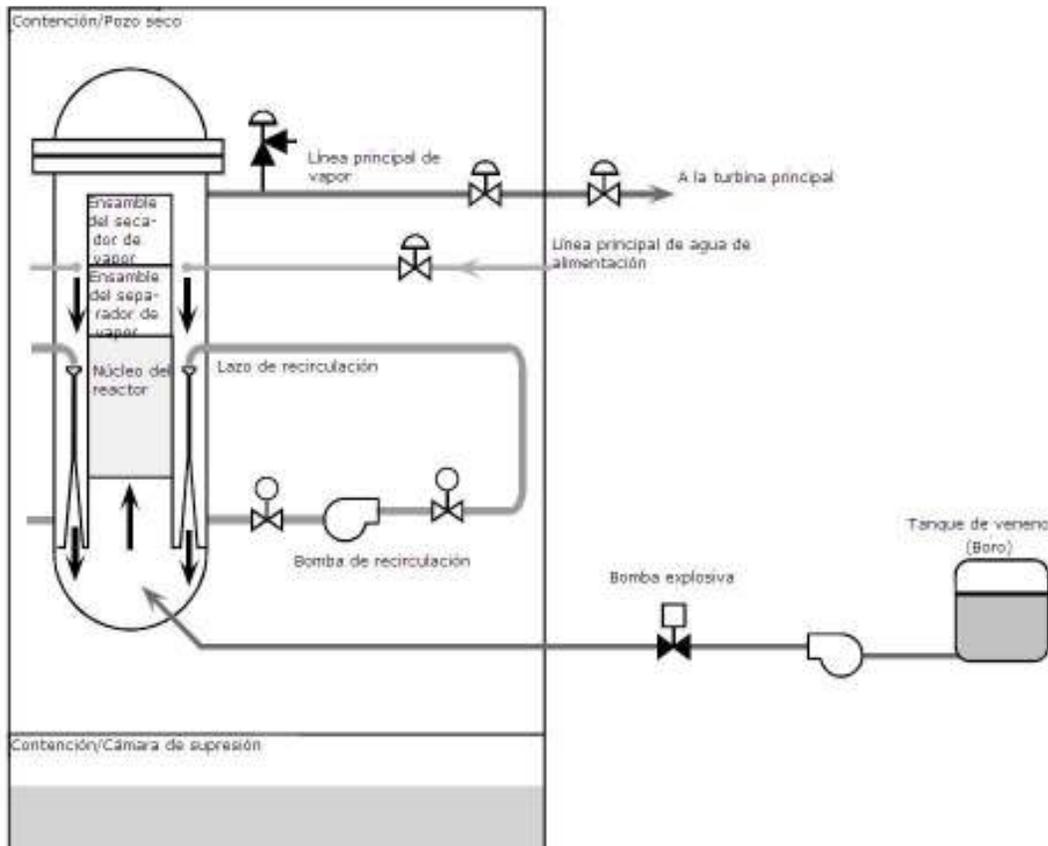


Figura 1.7. Esquema del Sistema de Control de Líquido de Reserva

1.1.6 Sistemas de Refrigeración de Emergencia del Núcleo (ECCS)

El ECCS provee de enfriamiento al núcleo en condiciones de un accidente de pérdida de refrigerante para limitar el daño al encamisado del combustible.

El ECCS consiste de 2 sistemas de alta presión y dos sistemas de baja presión. Los sistemas de alta presión (HPCIS) y el sistema de despresurización automática (ADS).

Los sistemas de baja presión son el modo de inyección del refrigerante a baja presión (LPCI) del sistema de remoción de calor residual (RHR) y el sistema de rocío al núcleo (RCS).

La manera en la cual ECCS opera para proteger al núcleo es función de la tasa a la cual se pierde el inventario del refrigerante del reactor por el rompimiento de la barrera del proceso del sistema nuclear.

Si el rompimiento en la barrera del proceso del sistema nuclear es de un tamaño tal que la pérdida del refrigerante excede la capacidad del HPCIS, la presión del reactor disminuye lo suficientemente rápido como para que los sistemas de enfriamiento de emergencia del núcleo a baja presión comiencen la inyección del refrigerante a la vasija del reactor a tiempo para enfriar al núcleo.

La despresurización automática sucede para reducir la presión del reactor si ha ocurrido un rompimiento y el HPCIS no se encuentra en operación. Se desea una rápida despresurización del reactor para permitir flujo de los sistemas de baja presión con el fin de que al aumento de temperatura en el núcleo se limite a menos de los requisitos regulatorios.

Si para un rompimiento dado, el HPCIS tiene la capacidad de compensar las pérdidas de refrigerante, no será requerido flujo de los sistemas de baja presión para la protección del núcleo hasta que la presión del reactor haya disminuido por debajo de los 100 psi aproximadamente.

1.1.6.1 Sistemas de Emergencia de Enfriamiento del Núcleo a Alta Presión

1.1.6.1.1 Sistema de Inyección de Refrigerante a Alta Presión (HPCI)

El HPCI (Figura 1.8) es un sistema independiente de enfriamiento de emergencia del núcleo que no requiere de potencia auxiliar de CA (Corriente Alterna), ni sistemas de ventilación de la planta o de sistemas de agua de enfriamiento externos para desempeñar su propósito de administrar agua de compensación a la vasija del reactor para enfriamiento del núcleo durante un accidente pequeño o intermedio de pérdida de refrigerante. El HPCI puede suministrar agua de compensación a la vasija del reactor desde una presión por arriba de la nominal del reactor hasta una presión en el reactor por debajo de la cual el sistema de baja presión de emergencia pueda inyectar.

1.1.6.1.2 Sistema de Despresurización Automática (ADS)

Consiste en la lógica redundante capaz de abrir válvulas de alivio y seguridad selectas, cuando es requerido, para despresurizar al reactor en eventos que involucren accidentes de pérdida de refrigerante de tamaño pequeño o intermedio si el HPCI no está disponible o no puede reparar el nivel de agua de la vasija del reactor.

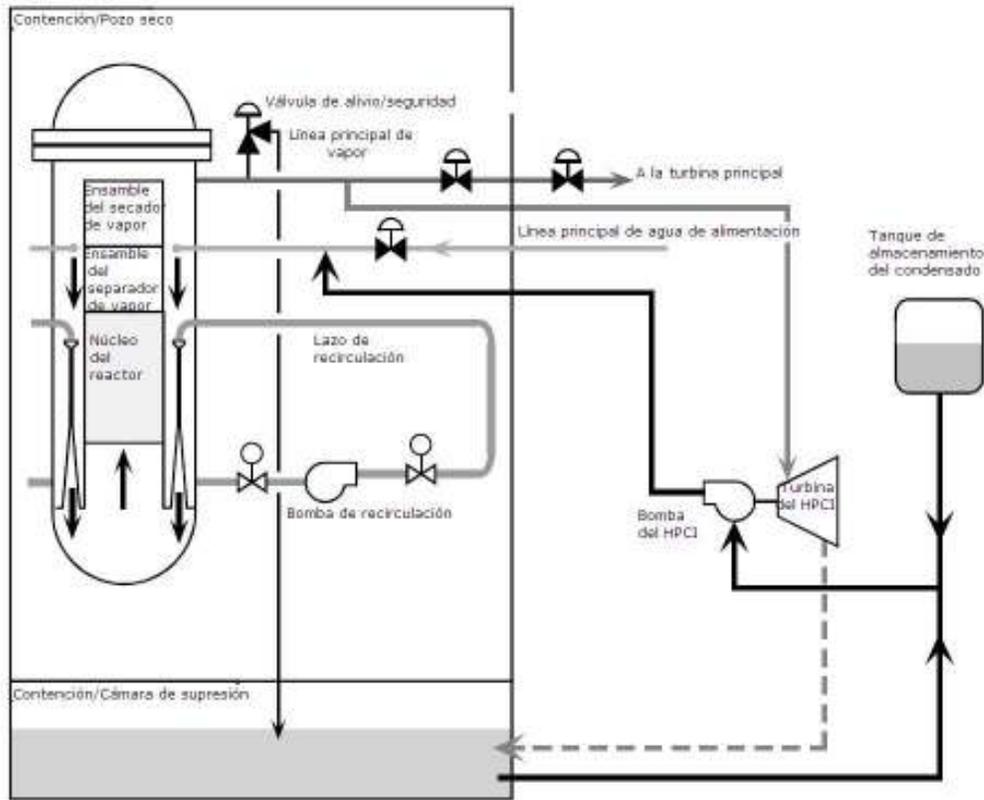


Figura 1.8. Esquema de los Sistemas de Emergencia de Enfriamiento del Núcleo a Alta Presión

1.1.6.2 Sistemas de Emergencia de Enfriamiento del Núcleo a Baja Presión

Consiste en 2 sistemas por separado e independientes:

1.1.6.2.1 El Sistema de Rocío del Núcleo (RCS)

Consiste en 2 lazos de bombeo, separados e independientes, cada uno capaz de bombear agua desde la alberca de supresión hasta la vasija del reactor. El enfriamiento del núcleo es llevado a cabo por el rocío de agua en la parte superior de los ensambles de combustible.

1.1.6.2.2 El Modo de Inyección de Refrigerante a Baja Presión del Sistema de Remoción de Calor Residual (LPCI del RHR)

Suministra agua de compensación a la vasija del reactor para enfriamiento del núcleo bajo condiciones de un accidente de pérdida de refrigerante. El RHR es un sistema de multipropósito con varios modos de operación, cada uno de éstos utiliza las mismas piezas principales del equipo.

El modo LPCI es el modo dominante y la configuración normal de alineación de válvulas del RHR. El modo LPCI opera automáticamente para restaurar y, si es necesario mantener el inventario de refrigerante de la vasija del reactor para evitar que las temperaturas del encamisado del combustible excedan los 2200°F.

Durante la operación del LPCI las bombas de remoción de calor residual toman agua de la alberca de supresión y la descargan en la vasija del reactor (Figura 1.9).

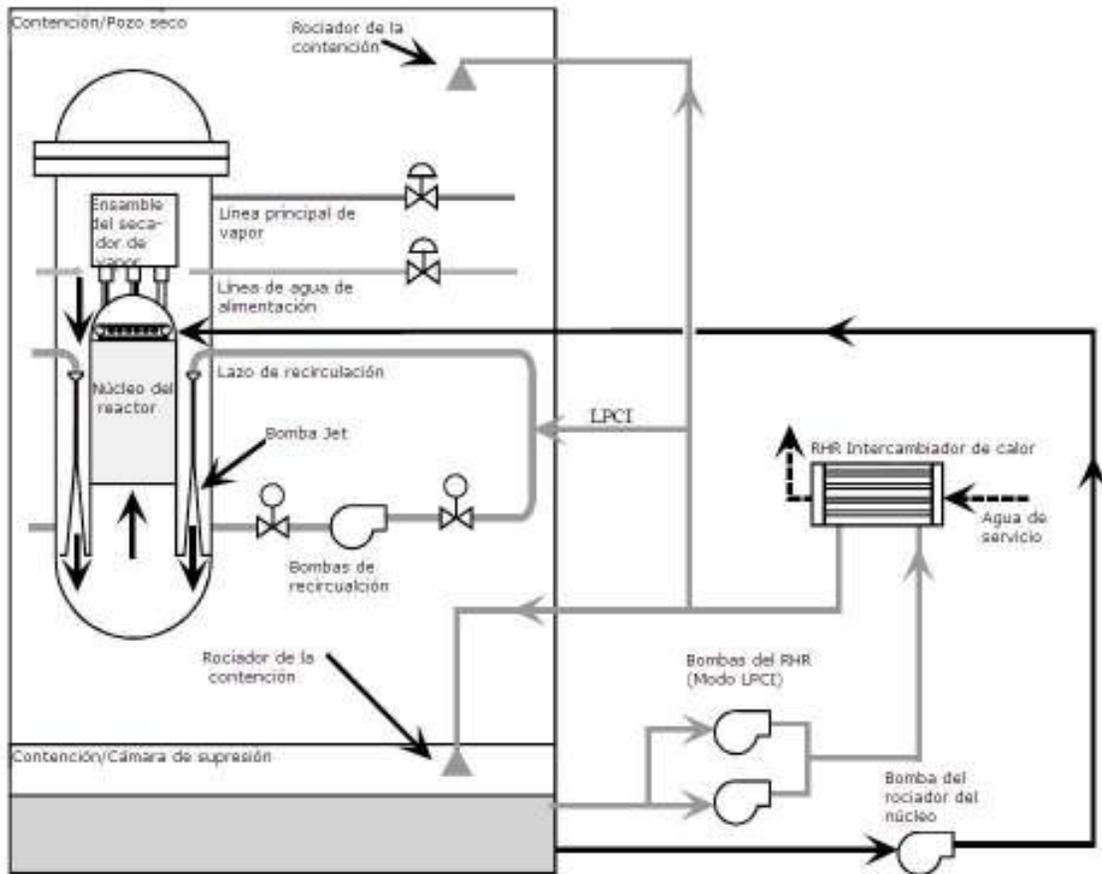


Figura 1.9. Esquema de Los Sistemas de Emergencia de Enfriamiento del Núcleo A Baja Presión

1.1.7 Tipos de Contención de los BWRs

La contención primaria para una línea de productos en particular, depende de la antigüedad de la planta y del análisis de costo beneficio desarrollado antes de que la central se construya.

Durante la evolución de los BWR, se construyeron 3 tipos principales de contención.

1.1.7.1 MARK I

El diseño de la contención del MARK I (Figura 1.10) tiene como principales componentes:

- ➔ El pozo seco, el cual rodea a la vasija del reactor y a los lazos de recirculación.
- ➔ Una cámara de supresión la cual almacena una gran cantidad de agua (alberca de supresión).
- ➔ Una red de verificación interconectada entre el pozo seco y la cámara de supresión.
- ➔ La contención secundaria la cual rodea a la primaria (pozo seco y alberca de supresión) y que alberga al combustible gastado y a los sistemas de emergencia de enfriamiento del núcleo.

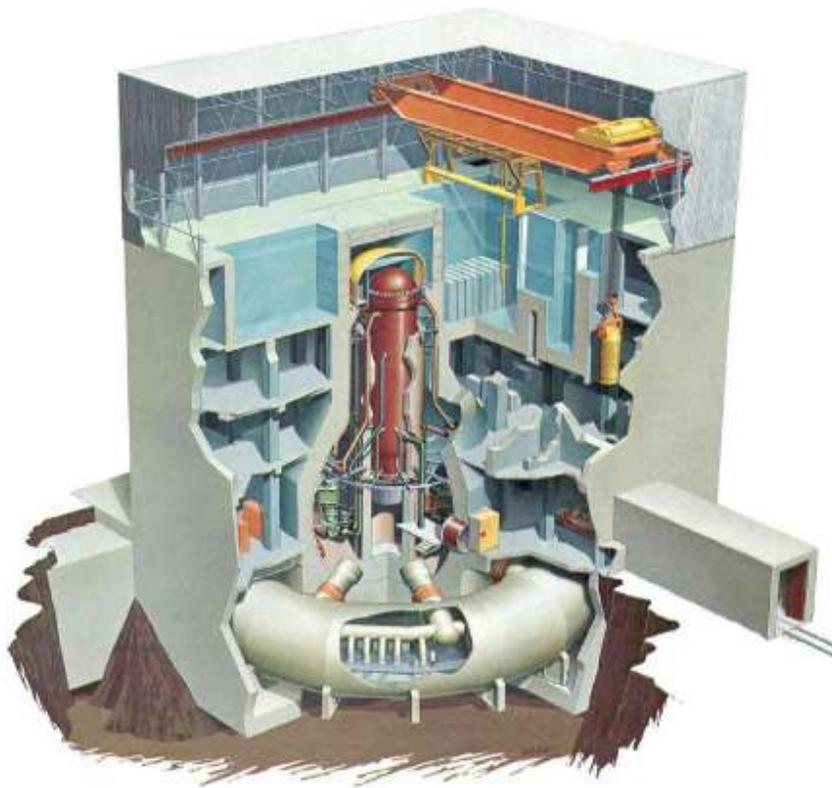


Figura 1.10. Esquema del MARK I

1.1.7.2 MARK II

La contención primaria del MARK II (Figura 1.11) consiste de un domo de acero y de una pared de concreto postensado o una pared de concreto reforzado construido sobre una capa de concreto reforzado.

La superficie interna de la contención está cubierta por una placa de acero que actúa como una membrana antifugas. La pared de la contención también sirve como soporte para las placas del piso del edificio del reactor (contención secundaria) y la alberca de reabastecimiento.

El pozo seco, en forma de cono truncado se localiza directamente por encima de la alberca de supresión.

La cámara de supresión es cilíndrica y está separada del pozo seco por una placa de concreto reforzado, la parte superior del pozo seco está ocupado por un domo de acero elíptico llamado cabeza del pozo seco.

La atmósfera inerte del pozo seco es ventilada hacia la cámara de supresión a través de una serie de tuberías que penetran y que son soportadas por el piso del pozo seco.

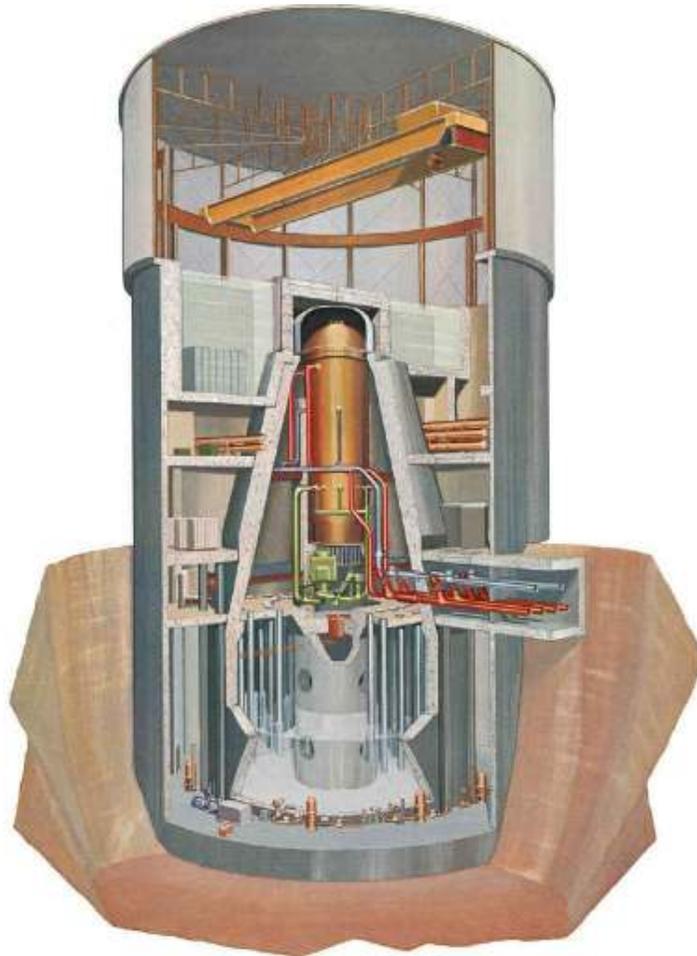


Figura 1.11. Esquema del MARK II

1.1.7.3 MARK III

En la contención primaria MARK III (Figura 1.12), el pozo seco es una estructura cilíndrica de concreto reforzado con una cabeza removible. El pozo seco está diseñado para soportar y confinar al vapor generado durante la ruptura de una tubería dentro de la contención y para canalizar el vapor liberado hacia la alberca de supresión a través del dique y de las ventilas horizontales.

La alberca de supresión contiene un volumen grande de agua para compensar rápidamente el vapor dirigido a ella. Una vasija de contención cilíndrica de acero a prueba de fugas rodea al pozo seco y a la alberca de supresión para prevenir que los productos sólidos y gaseosos de fisión escapen al ambiente en caso de una ruptura de la contención.

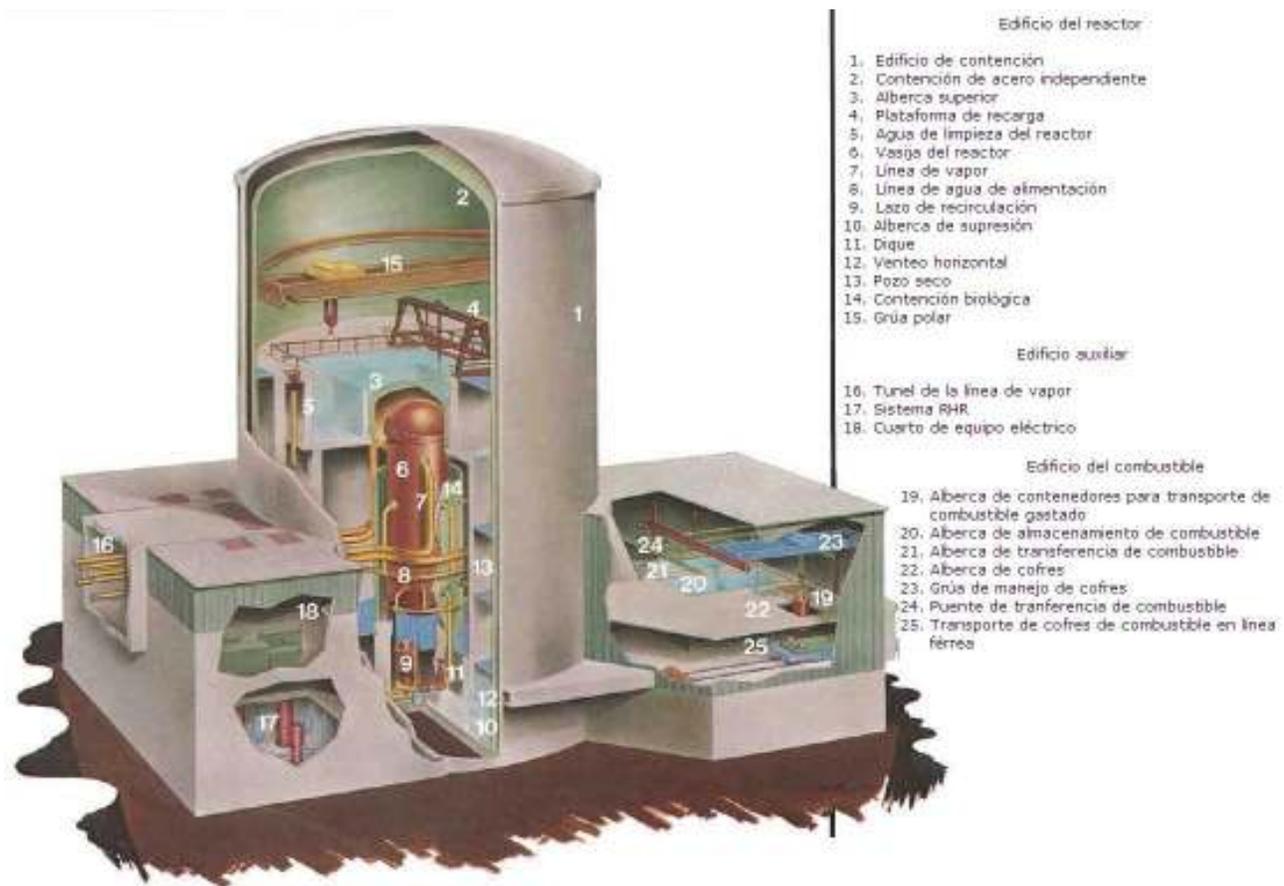


Figura 1.12. Esquema del MARK III

Los tres diseños de contención usan el principio de supresión de presión para accidentes de pérdida de refrigerante.

La contención primaria está diseñada para condensar el vapor y contener a los productos de fisión liberados por un accidente de pérdida de refrigerante de tal manera que no excedan la dosis de radiación permitida y para proveer el sumidero de calor además de ser una fuente de agua para ciertos equipos relacionados con la seguridad.

1.2 Evolución del BWR hacia el Reactor ABWR

El Reactor Avanzado de Agua en Ebullición (Advanced Boiling Water Reactor por sus siglas en inglés) (Figura 1.13) es un diseño avanzado de la compañía norteamericana General Electric y desarrollado en los años 80 bajo el auspicio de la compañía Japonesa TEPCO (Tokyo Electric Power Company).

El propósito del diseño del ABWR consiste en incluir cuidadosamente una mezcla de:

1. Las mejores funcionalidades de operación a nivel mundial de los BWRs.
2. Utilizar las mejores tecnologías disponibles.
3. Usar las nuevas técnicas de construcción modular.
4. Las mejoras en seguridad fueron, como siempre, la prioridad mayor, poniéndose atención especial en ir sistemáticamente reduciendo los costos de capital e incorporando funciones en el diseño de la planta, que hagan el mantenimiento significativamente más sencillo y eficiente.

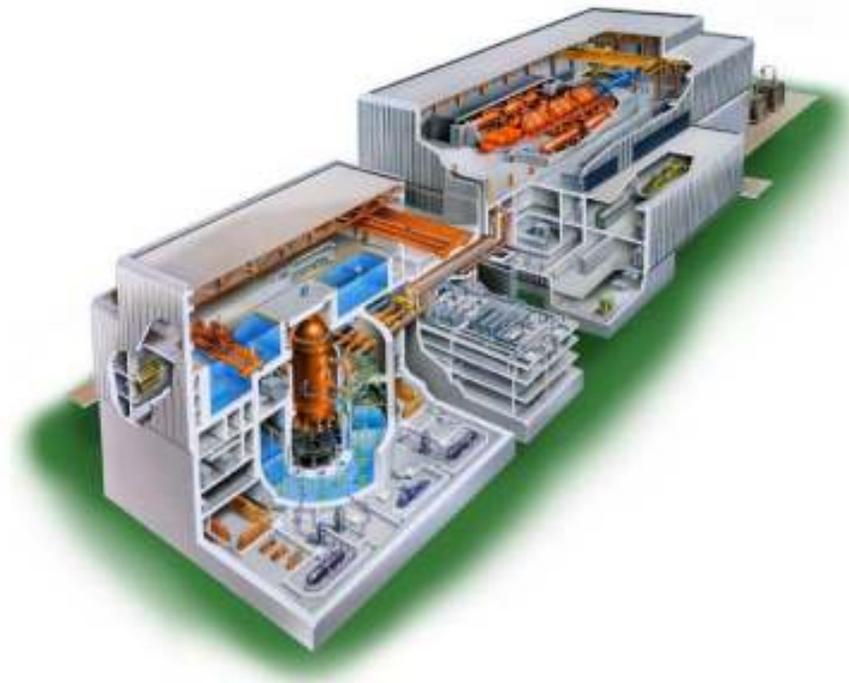


Figura 1.13. Esquema de un ABWR

Las metas específicas propuestas para el reactor ABWR son:

- Vida de diseño de 60 años.
- Factor de disponibilidad superior al 87%.
- Recarga cada 18-24 meses.
- Límite de exposición de radiación PPE < 1 Sv/año.
- Generación de residuos < 100 m³/año.
- Reducción de la frecuencia de daño al núcleo.
- Construcción en 48 meses.
- 20% de reducción de costos de capital con respecto a anteriores reactores BWR.

1.2.1 Simplificación de la Vasija

El reactor tipo ABWR utiliza bombas de recirculación internas y acopladas directamente a la vasija, para eliminar las bombas jet y los sistemas de recirculación externos, eliminando roturas potenciales de tuberías y evitándose posibles pérdidas de refrigerante, en la Figura 1.14 se muestra el proceso de evolución del reactor tipo BWR.

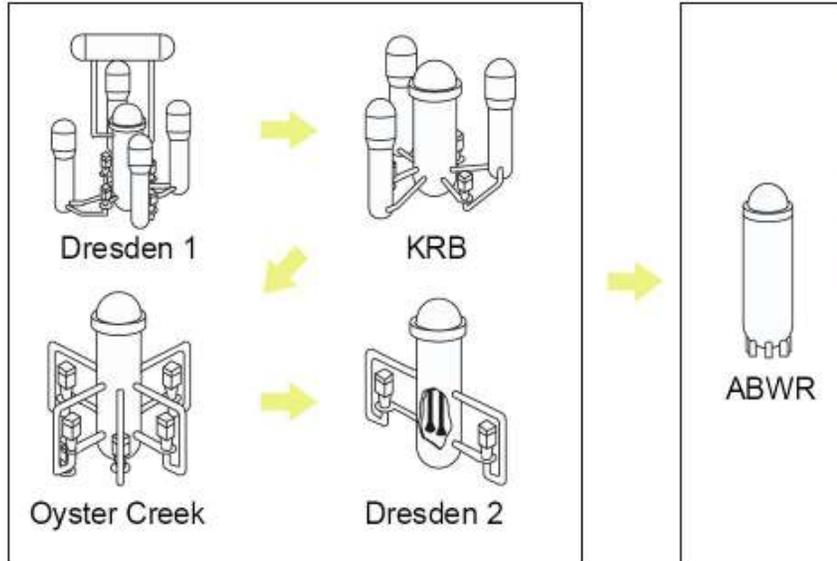


Figura 1.14. Eliminación de Lazos Externos

También, se elimina el 30% de las soldaduras de la vasija, a base de utilizar anillos en vez de placas, reduciendo las necesidades de Inspección en Servicio.

1.2.2 Rediseño de la Contención

Por otra parte las primeras contenciones de los BWRs eran estructuras esféricas secas, similares a aquellas usadas todavía en los diseños de PWR. Sin embargo, el BWR rápidamente se cambió al diseño de contención "supresión de presión" debido a sus múltiples ventajas, entre éstas están:

- Capacidad de alta temperatura
- Presión de diseño inferior
- Habilidad superior para adaptarse a una rápida despresurización
- Habilidad única para filtrar y retener productos de fisión
- Una provisión amplia de agua de compensación lista en caso de accidente
- Diseño simplificado y compacto

La contención del ABWR es significativamente menor que la contención MARK III debido a que la eliminación de los lazos de recirculación se traduce en una contención y un edificio de reactor más compactos. La vasija está hecha de concreto reforzado con un *liner* de acero (RCCV).

El reactor ABWR garantiza la integridad de la contención en accidentes severos gracias a la utilización de nitrógeno, el cual es un gas inerte. Dispone del Edificio de Contención, que es en sí mismo, la contención secundaria incluyendo las funciones del edificio auxiliar y de combustible.

1.2.3 Redundancia de los Sistemas

Este reactor cuenta con tres generadores Diesel de emergencia para minimizar la posibilidad de una pérdida total de energía en la central. Cuenta con la existencia de tres divisiones de sistemas de emergencia que incluyen la capacidad de extracción de calor residual, así como la inyección a baja y alta presión.

Presenta mejoras en cuanto a la respuesta ante transitorios anticipados sin *SCRAM* (apagado súbito del reactor), con la adopción de un sistema de barras de control que permite la parada del reactor, tanto por medios hidráulicos como eléctricos.

Otro de los puntos importantes en el diseño de este reactor, es la incorporación de instrumentación y control digital con diagnósticos automáticos. Se emplean multiplexores y fibra óptica para eliminar la necesidad de cables y transmisores. Se dispone de tres canales redundantes en los procesos de control de sistemas primarios, para poder hacer mantenimiento en línea.

1.3 El Reactor Avanzado de Agua en Ebullición

1.3.1 La Vasija del Reactor

Las principales diferencias de la vasija del reactor ABWR con respecto a los reactores BWR que le preceden, son (Figura 1.15):

- Brida de la vasija de tipo interno.
- Penetraciones de vapor con restrictores de flujo.
- Doble penetración de agua de alimentación con manga térmica.
- Borde de soporte de la vasija cónico.
- Parte inferior relativamente plana.
- Eliminación de penetraciones por abajo del nivel del núcleo.
- Bombas de recirculación internas.
- Uso de anillos forjados.

Montaje del ABWR

1. Brida de la vasija y cierre superior
2. Rociador de la cabeza
3. Restrictor del flujo de salida del vapor
4. Estabilizador de la vasija de presión del reactor
5. Boquilla de entrada del agua de alimentación
6. Anillos forjados de la coraza
7. Faldón soporte de la vasija
8. Cabeza inferior de la vasija
9. Penetraciones de las bombas internas del reactor
10. Aislamiento térmico
11. Envolvente del núcleo
12. Placa del núcleo
13. Guía superior
14. Soportes del combustible
15. Alojamiento de los mecanismos de las barras de control
16. Tubos guía de las barras de control
17. Alojamiento dentro del núcleo
18. Estabilizadores y tubos guía de los instrumentos del núcleo
19. Rociador del agua de alimentación
20. Rociador de inundación del núcleo a alta presión (HPCF)
21. Acoplamiento del HPCF
22. Inundador de baja presión (LPFL)
23. Salida de enfriamiento de apagado
24. Separadores de vapor
25. Secador de vapor
26. Bombas internas del reactor (RIP)
27. Cubierta del motor de las RIP
28. Línea de presión diferencial del núcleo y de las RIP
29. Mecanismos de movimiento fino de las barras de control
30. Ensamblajes de combustible
31. Barras de control
32. Monitor del rango local de potencia

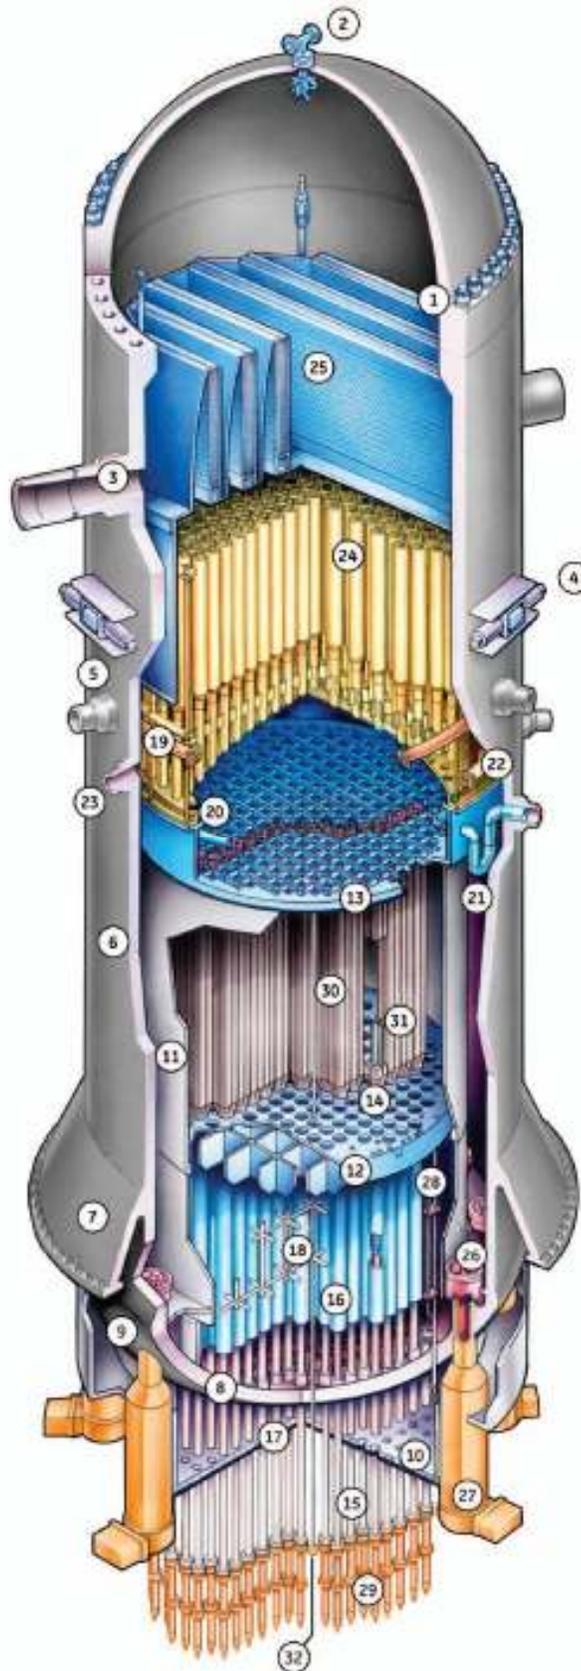


Figura 1.15. Vasija del Reactor ABWR

1.3.2 El Núcleo del Reactor

El núcleo del reactor ABWR está configurado en forma de cilindro conteniendo, por lo general, 872 ensamblajes de combustible (Figura 1.16), localizado dentro de la vasija del reactor. El núcleo incluye, además de los ensamblajes de combustible, las barras de control y la instrumentación nuclear.

El núcleo del ABWR es similar a los núcleos de BWR existentes y puede aceptar ensamblajes de combustibles que son aplicables a BWRs /4-6 con modificaciones mecánicas menores.

La experiencia sobre el combustible en otros BWRs es aplicable al núcleo del ABWR. La geometría del ensamblaje de combustible dentro del canal para aplicación en un ABWR es idéntica a la aplicación en BWR/4-6 con la siguiente característica: el paso del ensamblaje se incrementa en 0.254 cm (15.494 cm vs 15.24 cm)

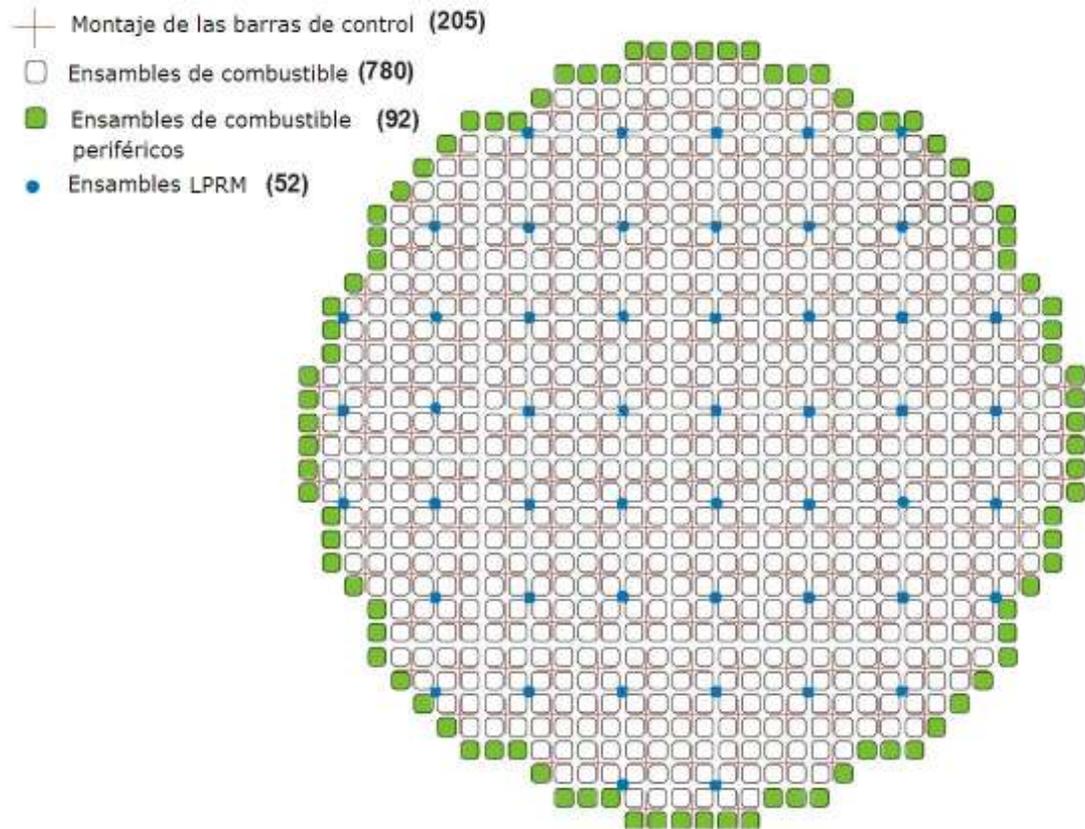


Figura 1.16. Configuración del Núcleo del Reactor Tipo ABWR

1.3.2.1 Ensamble de Combustible

El ensamble de combustible tipo GE12 y GE14 pertenecen a la generación de ensambles con arreglo de barras de combustible 10x10.

El diseño GE14 (ver Fig. 1.17) mantiene la mayoría de las características del diseño GE12, como son; 92 barras de combustible, de las cuales 14 son barras de longitud parcial, dos barras centrales de agua, canales de 3.9076 cm, encamisado con barrera, 8 espaciadores de alto desempeño distribuidos a lo largo del ensamble, filtro para basura "debris", diferentes enriquecimientos axiales de Gadolinio y de U_{235} (Tabla 1.1).



Figura 1.17. Esquema de un Ensamble de Combustible

Característica	GE12	GE14
Número total de barras de combustible	92	No cambia
Número de barras de agua	2	No cambia
Número de barras espaciadoras	8	No cambia
Número de barras parciales	14	No cambia
Longitud activa del combustible en barras parciales (cm)	236.2	213.4
Peso típico del ensamble (KgU)	181	178
Pitch entre barras de combustible (cm)	1.295	No cambia

Tabla 1.1. Comparación entre el Diseño GE14 y GE12

Dentro de las nuevas características del combustible GE14, que permitirán optimizar la energía generada, están las siguientes:

- i. Reducción en la longitud de las barras parciales (15.24 cm menos en comparación con el GE12) logrando con esto: aumentar la relación moderador-combustible en la parte superior del núcleo, reducir la caída de presión provocada por la presencia del flujo en dos fases, con esto mejora la estabilidad termohidráulica del ensamble y del núcleo mismo, además de reducir el peso de UO_2 .
- ii. De los 8 espaciadores, los 3 de la parte superior del ensamble están colocados a una distancia menor uno de otro, en comparación de los 5 restantes. Esto mejora el desempeño del ensamble en cuanto a la potencia crítica (CPR), respecto al diseño del GE12.

En la Tabla 1.2 podemos ver los datos técnicos más importantes del reactor avanzado de agua en ebullición.

Potencia eléctrica neta	1356 [MWe]	Potencia térmica bruta	3926 [MWt]
Núcleo del reactor			
Altura	3.71 [m]		
Diámetro	5.16 [m]		
Elementos de Combustible	872		
Potencia Lineal Promedio	196 [W/cm]		
Densidad de Potencia Promedio	50.6 [kW/L]		
Combustible			
Material de combustible	UO ₂ , UO ₂ -Gd ₂ O ₃		
Enriquecimiento promedio por recarga	3.5%		
Número de varillas por arreglo de ensamble	92		
Diámetro de la barra de combustible	12.3 [mm]		
Material del encamisado	Zircaloy 2		
Espesor del encamisado	0.86 [mm]		
Quemado de descarga del combustible	45,000 [MWd/t]		
Sistema de control			
Número de barras de control	205		
Forma de las barras de control	Cruciforme		
Absorbedor de neutrones	B ₄ C		
Mecanismo de las barras de control	Movimiento eléctrico fino, SCRAM hidráulico		
Sistema de enfriamiento primario			
Tipo	Recirculación interna, sistema de bombeo		
Presión de operación	73.1 [kg/cm ²]		
Temperatura de admisión del agua de alimentación	215.5 [°C]		
Temperatura del vapor de salida	287.4 [°C]		
Número de bombas de recirculación	10		
Masa del flujo de recirculación	52,200 [T/h]		
Vasija de presión del reactor			
Altura interna	21 [m]		
Diámetro interno	7.1 [m]		
Espesor mínimo de la pared	174 [mm]		
Materiales	Revestimiento de acero inoxidable		
Contención			
Tipo	Concreto reforzado		
Vasija de contención	Laminada con acero		
Presión de diseño	3.16 [kg/cm ²]		
Altura	36.1 [m]		
Turbina			
Número	1		
Valor máximo a 722 [mmHg]	1381 [MWe]		
Velocidad	1500 [rpm]		
Presión de admisión	69.2 [kg/cm ²]		
Temperatura de admisión	283.7 [°C]		

Tabla 1.2. Datos Técnicos de un ABWR



El diseño de combustible es un proceso que involucra diferentes etapas dependientes entre sí con el fin de hacer más eficiente el uso del combustible y mantener la operación del reactor óptima y segura. Este capítulo describe las diferentes etapas y las características más importantes del diseño de combustible.

La gestión de combustible dentro del núcleo tiene que ver principalmente con la estrategia empleada para la carga de combustible en el núcleo. Su objetivo principal es optimizar los parámetros de quemado de combustible para minimizar los costos del combustible y al mismo tiempo cumplir con una generación continua de potencia de manera confiable y segura. Para lograr esto, la estrategia se basa en obtener la distribución de potencia más uniforme y consistente con otros requisitos de diseño durante toda la operación. Además, el quemado en el combustible descargado debe ser lo más uniforme posible.

Se han propuesto varios esquemas para alcanzar estos objetivos generales, en la mayoría de los casos la carga de combustible es secuencial, de manera tal que en cualquier momento dado haya en el núcleo combustible fresco que contiene pocos productos de fisión y combustible con quemado considerable. La reactividad asociada con la inserción de combustible fresco extiende la exposición que es posible con el combustible gastado; al mismo tiempo, el combustible más viejo, que sirve de alguna manera como veneno quemable, compensa a esta reactividad sin requerir un gran inventario de antireactividad en las barras de control.

Como tendencia general el enriquecimiento del combustible fresco debe incrementarse conforme se busquen mayores quemados. Sin embargo, las áreas locales de enriquecimiento alto pueden llevar a áreas locales de alta potencia no deseadas. Por lo tanto el acoplamiento neutrónico entre un área y otra se vuelve muy importante en la planeación de la carga. Una interacción complicada entre un número de factores, tales como el enriquecimiento, la reactividad, el transporte de neutrones y la potencia, cada uno dependiente del tiempo y el espacio, afectan el problema

En un BWR se puede usar el movimiento de las barras de control y el ajuste de distribución de vacíos mediante la variación de la tasa de recirculación para aplanar la distribución de potencia. De esta manera la distribución espacial del quemado de combustible también puede ser controlada para contrarrestar el efecto de vacíos al final del periodo de exposición del combustible cuando permanecen pocas barras de control en el núcleo. (Sesonske, 1973)

2.1 Objetivo de la Administración de Combustible dentro del Núcleo

El tiempo de vida útil de un reactor nuclear BWR se divide en intervalos de operación denominados ciclos de operación. Al final de cada ciclo de operación se incluye un lapso de tiempo para realizar el recambio de los ensambles de combustible más gastados por ensambles frescos (aproximadamente entre un cuarto y un tercio del total).

Durante el ciclo de operación, el combustible (UO₂) cargado en el reactor permanece generando energía hasta que la reactividad* del núcleo es tan pequeña que es imposible seguir operándolo bajo condiciones de diseño. Entonces, viene la etapa de recarga en la que ensambles con combustible fresco son introducidos al reactor para iniciar un nuevo ciclo.

Esto exige que antes de cargar el combustible al reactor, se realicen análisis del diseño del ciclo de operación. Estos análisis consisten de varias etapas interdependientes que siguen un esquema de cálculo iterativo en etapas y constituyen las actividades de la administración de combustible dentro del núcleo del reactor (Figura 2.1).

* Parámetro que caracteriza la criticidad de un reactor (Blanco)

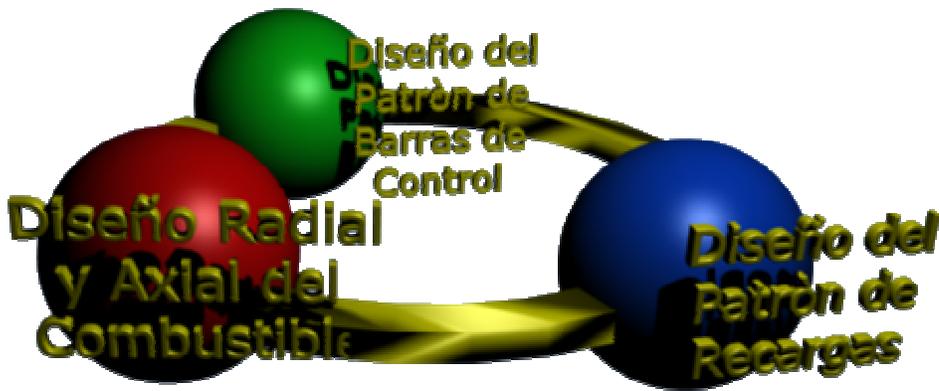


Figura 2.1. Proceso Global De Optimización Iterativo

El diseño de recargas de combustibles de un BWR involucra varias etapas de optimización relacionadas entre sí. Dos de ellas tienen que ver con el diseño de los ensambles combustibles. Éstos son conjuntos de barras que contienen combustible (dióxido de uranio) con diversos contenidos de material fisible (enriquecimiento en U^{235}) y de veneno consumible Gd_2O_3 (Gadolinia), y barras que contienen agua.

A las secciones transversales de estos ensambles se les llama celdas de combustible. En la primera etapa de optimización se diseñan radialmente (Figura 2.2) las celdas de combustible que van a acomodarse a lo largo del ensamble, es decir, se determina la distribución radial de diferentes enriquecimientos y contenidos de Gadolinia.

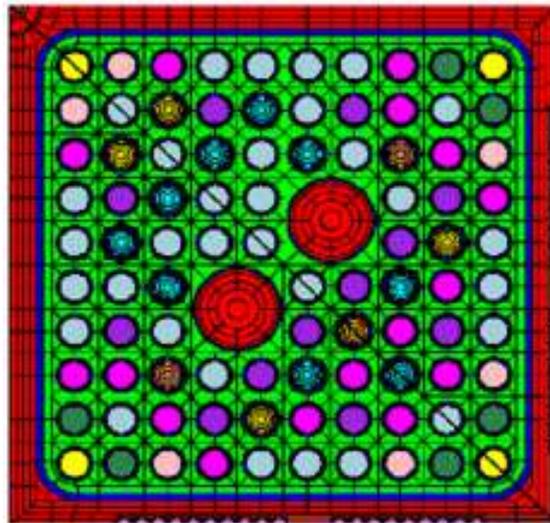


Figura 2.2. Sección radial de una celda de combustible

La segunda etapa es diseñar el acomodo axial (Figura 2.3) de las diferentes celdas de combustible que van a integrar un ensamble completo. Una tercera etapa de optimización tiene que ver con el patrón de recarga de los ensambles combustibles dentro del núcleo. En esta etapa se define la localización de ensambles nuevos y usados en el núcleo. Para ello se toman en cuenta las diversas zonas dentro del núcleo: la periferia, las posiciones de celdas de control utilizadas para operar el reactor, los ejes de simetría, etc.

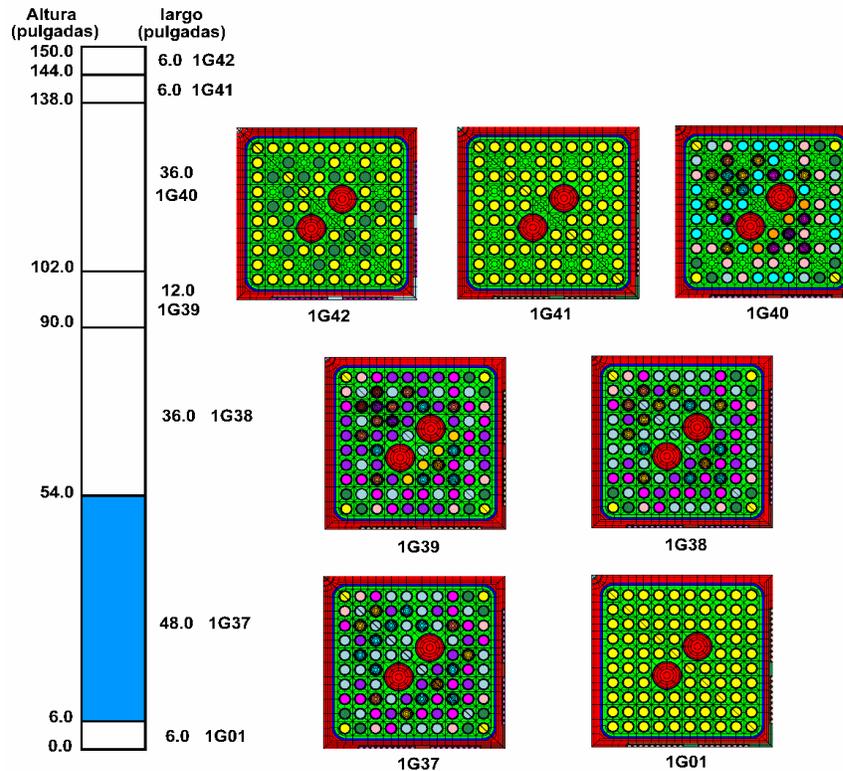


Figura 2.3. Ejemplo de una descripción axial de un ensamblaje combustible

Una cuarta etapa de optimización es diseñar lo que se llama el patrón de barras de control y el flujo de refrigerante a diferentes pasos de quemado (irradiación) a lo largo del ciclo de operación del reactor.

Una etapa más de optimización tiene que ver con el diseño de multiciclos en el que se engloba la operación del reactor a lo largo de su vida.

Cada una de estas actividades incluye resolver un problema de optimización de tipo combinatorio sujeto a restricciones. Las actividades no son independientes entre sí, y van dirigidas a optimizar la economía, a facilitar la operación y a satisfacer los requerimientos de seguridad del reactor. De esta manera, la administración del combustible dentro del núcleo tiene los siguientes objetivos:

1. Asegurar que cada *nuevo núcleo* va a generar la energía para lo cual ha sido diseñado.
2. Garantizar que las características de seguridad del combustible sean iguales o mejores que las reportadas en el informe de seguridad, esto es, que satisfagan los requerimientos de seguridad del reactor: límites térmicos y de margen de parada, durante todo el ciclo y para los ciclos de la vida útil de la planta.
3. Optimizar la economía: extraer del combustible la mayor cantidad de energía durante toda su estancia en el reactor.
4. Facilitar la operación del reactor: requerimientos de reactividad con y sin barras de control.
5. Hacerlo en los tiempos adecuados para realizar oportunamente las compras de uranio, conversión y enriquecimiento y fabricación de ensamblajes, etc.

2.2 Actividades de Diseño de Recargas

El diseño de recargas esta compuesto por el diseño del ensamble combustible, el diseño del patrón de recarga (444 canales) y el diseño del patrón de barras de control (109 barras, 24 posiciones axiales).

2.2.1 Diseño del Ensamble Combustible

Inicialmente se realiza el diseño y optimización radial de las celdas de combustible. Este diseño se basa en cálculos neutrónicos de celdas de combustible, con el propósito de optimizar la distribución (radial) del enriquecimiento de U^{235} y de Gadolinia dentro de los ensambles de combustible que serán introducidos en la recarga de combustible del núcleo, de modo que se cumplan las bases de diseño tanto de seguridad como de operación. Esta etapa debe tomar en cuenta las diferentes partes de la celda de combustible, en especial las composiciones utilizadas en el arreglo de 10×10 formado por las barras de combustible que pueden contener tanto óxido uranio enriquecido en U^{235} (2 a 5 %), como óxido de uranio enriquecido (2 a 5%) mezclado con gadolinia (Gd_2O_3) además de barras vacías y barras de agua. Este es el tema principal de este trabajo de tesis.

Otra etapa del diseño del ensamble es el diseño y optimización axial. En esta etapa se busca la distribución axial óptima de celdas (radiales) de combustible que conforman axialmente el ensamble de combustible fresco que será introducido en el lote de combustible nuevo que se recargará en el núcleo. Este tema no se aborda en el presente trabajo de tesis.

2.2.2 Diseño de Patrones de Recargas

El núcleo de un BWR tiene varios cientos de ensambles de combustible. Para cada ciclo de recarga, aproximadamente un cuarto de los ensambles de combustible en el núcleo son reemplazados por ensambles frescos, el resto son ensambles de combustible quemado conservados del ciclo previo. El conjunto de combustibles conservados y frescos es acomodado en la posición óptima para la seguridad y el desempeño del núcleo del siguiente ciclo e inclusive de ciclos futuros. Cada ensamble combustible tiene una exposición y una historia diferente y el grado de agotamiento del combustible quemado influirá en la distribución de potencia y la longitud del ciclo. (Kobayashi, 2001)

El diseño de la recarga de combustible y de los patrones de barras de control (PBC) son dos problemas de optimización de complejidad similar.

Por ejemplo, en los reactores de la Central Núcleo-eléctrica Laguna Verde (CNLV) existen 444 canales donde deben asignarse 444 elementos combustibles, esto implica que en principio habría 444! posibles soluciones al problema, si todos los ensambles fueran diferentes. Sin embargo, todos los combustibles frescos del mismo lote son idénticos y además combustibles ya quemados del mismo lote que han ocupado posiciones simétricas en el núcleo y condiciones de inserción de barras iguales, se pueden considerar "idénticos" para fines del diseño de recarga. Los ensambles quemados pueden tener permanencias de 1 a 4 ciclos de operación anteriores y con diferentes enriquecimientos y contenidos de gadolinia

El patrón de recarga involucra la toma de decisiones acerca del número de ensambles frescos, la localización de los ensambles de combustible en el núcleo y el patrón de barras de control como función de la exposición del ciclo. Este tema no fue estudiado en el presente trabajo.

2.2.3 Diseño de Patrón de Barras de Control (PBC)

A cada recarga de combustible se le asocia un conjunto de patrones de barras de control para la operación del ciclo. Existen 109 barras de control que pueden ubicarse en 25 posiciones axiales distintas, lo que quiere decir que en principio hay $(25)^{109} \sim 3 \times 10^{152}$ configuraciones diferentes para un PBC aplicado a un paso de quemado específico durante el ciclo.

Considerando que se deben de proponer para los distintos pasos de quemado, entonces el universo de posibilidades aumenta a $((25)^{109})^{j-1}$ posibilidades; donde j es el número de pasos de quemado. En el diseño de un ciclo de operación típico j varía entre 10 y 15 pasos dependiendo de la longitud del ciclo y del detalle que se requiera hacer en cuanto al patrón de barras de control. El diseño de patrón de barras tampoco se considera en esta tesis.

2.3 Variables Importantes a Considerar en el Diseño de Combustible

Como ya se mencionó, para el diseño neutrónico de recargas, se considera que el diseño mecánico y térmico de los ensambles combustibles ha sido realizado previamente por especialistas en mecánica y termohidráulica. En la operación del reactor se establecen los límites de seguridad para garantizar que éste pueda ser operado de manera segura bajo cualquier condición real de operación.

El objetivo del establecimiento de los límites térmicos para la operación normal y de los eventos transitorios es mantener la integridad del encamisado del combustible. Esto se logra al limitar el calor generado y por tanto la densidad de potencia de cada una de las barras de combustible, evitando sobretensión del encamisado del combustible debido a la expansión diferencial pastilla-encamisado. De este modo se asegura que no se funda la barra de combustible. La ebullición de transición debe ser evitada también para impedir daños al encamisado debido al sobrecalentamiento.

Estos límites deben ser considerados en los procedimientos de diseño y optimización de combustible dentro del núcleo y los principales son los siguientes:

El factor de pico de potencia local (LPPF, Local Power Peak Factor), se calcula a nivel de celda de combustible y se define como la razón de generación de potencia máxima producida por una barra de combustible (pin) sobre la potencia promedio de las barras contenidas en la celda. Como se verá más adelante, el factor de pico de potencia local es uno de los parámetros que se utiliza en el diseño de la distribución de enriquecimientos dentro de la celda de combustible.

El factor de pico de potencia (PPF, Power Peak Factor) en el núcleo está caracterizado por dos factores: a) El factor de pico de potencia radial, el cual se define como la razón de la potencia de un ensamble de combustible individual sobre la potencia promedio por ensamble del núcleo y es una función de la distribución radial de potencia en el núcleo, y b) El factor de pico de potencia axial, el cual se define como la razón de la potencia de un nodo axial de un ensamble de combustible específico sobre la potencia nodal promedio para este ensamble y es una función de la distribución axial de potencia en el ensamble.

El MCPR (Minimum Critical Power Ratio) es la razón mínima de potencia crítica para un tipo de ensamble dado. Este límite se establece para evitar que se presente la ebullición de transición en algún ensamble combustible, previniendo la falla del encamisado del combustible por estar sometido a un sobrecalentamiento. El MCPR es una función de varios

parámetros entre los que destacan la potencia del ensamble, el flujo en el ensamble y los detalles del diseño mecánico del ensamble. El valor límite es seleccionado para cada tipo de ensamble de manera tal que durante el evento más limitante, el CPR calculado en dicho ensamble no sea menor que el límite de seguridad MCPR.

La máxima generación lineal de calor (MLHGR, Maximum Linear Heat Generation Rate), medida en W/cm, expresa la generación de potencia por unidad de longitud de combustible. Otro parámetro que evalúa el desempeño del combustible es la razón promedio de generación de calor lineal en un plano (APLHGR, Average Planar Linear Heat Generation Rate). El máximo valor del APLHGR se define como el MPGR (Maximum Power Generation Rate), el cual se refiere a la Razón de Generación de Potencia Máxima. Este parámetro se obtiene al promediar la tasa de generación de calor lineal en cada barra de combustible en el plano y su valor límite se selecciona de manera tal que la temperatura pico del encamisado durante un accidente base de diseño de pérdida de refrigerante no exceda un valor dado en el plano de interés.



Algoritmos Genéticos

El problema del diseño radial de combustible es un problema combinatorio que puede resolverse mediante alguna técnica de optimización. Los algoritmos genéticos son un método meta heurístico de optimización con buenos resultados en problemas combinatorios. Este capítulo hace una descripción detallada de la técnica de los algoritmos genéticos, sus fundamentos (Mandago, 2006) así como sus ventajas y desventajas (Marczyk, 2004).

Los Algoritmos Genéticos (AG) son una técnica para solucionar problemas de optimización que intentan simular los mecanismos de la evolución natural, resultantes de la adaptación de los seres vivos al medio ambiente.

Esta técnica establece analogías con los mecanismos que provee la naturaleza buscando adaptar soluciones potenciales (cromosomas o individuos) a un medio en función de su aptitud o ajuste (dado por el mérito del individuo en la población). Esto implica que, en general, un AG puede resolver problemas de optimización de funciones sin exigir continuidad ni derivabilidad.

El mecanismo de los AG se basa en la modificación iterativa de una población de individuos candidatos a solución mediante el uso de operadores genéticos. La teoría de los AG está explicada en (Goldberg, 1989) y (Michalewicz, 1995).

El término Algoritmo Evolutivo, en realidad engloba una serie de técnicas de búsquedas inspiradas en la biología (teoría neo-Darwiniana de la evolución natural) basada en los mecanismos de la naturaleza, de acuerdo a los cuales los individuos más aptos de una población sobreviven al adaptarse mejor a los cambios que se producen en su entorno. Esto explica el empleo de términos biológicos, tales como la denominación de cromosomas a los individuos y gen a los bits que conforman esos individuos o cromosomas.

En términos generales, para simular el proceso evolutivo en una computadora se requiere:

- Estructuras codificadas que puedan repetirse
- Operaciones que afecten a los individuos
- Una función de aptitud
- Un mecanismo de selección

El mecanismo de resolución de problemas evolutivos puede esquematizarse como se muestra en la Figura 3.1



Figura 3.1. Esquema de Funcionamiento de un Algoritmo Evolutivo

Los AG son algoritmos estocásticos que mantienen una población P de n individuos,

$$P(t) = [x_1^t, \dots, x_n^t] \dots\dots\dots(3.1)$$

para cada iteración t . Cada individuo representa una solución potencial al problema a tratar, la cual es implementada como alguna (posiblemente compleja) estructura de datos S.

Cada solución x_i^t es evaluada cuantificando su aptitud. Posteriormente se seleccionan individuos de la población para conformar una población intermedia (o conjunto de apareamiento) que es transformada por la acción de los llamados operadores genéticos para luego aplicar un mecanismo de reinserción que arrojará como resultado una nueva población (iteración $t+1$).

Los operadores genéticos son transformaciones que tienen lugar sobre los individuos. Algunos miembros sufren transformaciones unarias mi (mutación), que crean un nuevo individuo ($mi: S \rightarrow S$) y transformaciones de orden más alto cj (tipo cruzamiento) que crean nuevos individuos combinando parte de algunos (dos o más) individuos ($cj : S \times S \dots \times S \rightarrow S$).

El algoritmo se ejecuta para cierto número de generaciones o hasta que se satisface algún criterio de detención.

Un Algoritmo Evolutivo debe tener al menos cinco componentes básicos (Michalewicz, 1996):

Una representación genética de las soluciones.

1. Una forma de crear una población inicial de soluciones.
2. Una función de evaluación (llamada también función objetivo) que "clasifica" las soluciones en términos de su adaptabilidad o aptitud.
3. Operadores genéticos que alteran la composición genética de los hijos durante la reproducción.
4. Valores de los parámetros (tamaño de la población, probabilidad de aplicar los operadores genéticos, etc.).

También es conocido que para lograr una implementación exitosa de una técnica evolutiva en un problema concreto, los componentes básicos listados anteriormente requieren de la incorporación de alguna estrategia adicional como por ejemplo la aportación de conocimiento específico del problema.

Los métodos de búsqueda de los AG modelan un fenómeno natural, es decir, tratan de simular lo que hace la propia naturaleza en la búsqueda de la o las soluciones óptimas para un problema de evolución dado. Pertenecen, además, a los algoritmos probabilísticos pero no son simplemente aleatorios porque combinan elementos de búsqueda directa y estocástica.

Una característica fundamental es que mantienen una población de soluciones potenciales, llevando a cabo una búsqueda multidireccional e intercambiando información entre esas soluciones, mientras que otros métodos procesan sólo un punto del espacio de búsqueda.

Para modelar los procesos de la naturaleza los AG deben representar procesos de selección, recombinación, mutación, y estructuras de población que se describirán a continuación.

A diferencia de otros métodos de optimización que trabajan sobre una solución inicial y van refinándola sucesivamente, un AG trabaja con una población de soluciones (individuos) que evolucionan. Esta característica le da al AG posibilidades de paralelizar más fácilmente la búsqueda.

3.1 Representación Genética de las Soluciones

La aplicación más común de los algoritmos evolutivos ha sido la solución de problemas de optimización, donde han demostrado ser muy eficientes y confiables. Sin embargo, no es aplicable para la resolución de todos los problemas de este tipo, por lo cual es necesario, antes de su aplicación, tener en cuenta las siguientes características:

- El espacio de búsqueda (es decir, las posibles soluciones) debe estar delimitado dentro de un cierto rango.
- Debe poder definirse una función de aptitud que nos indique qué tan buena o mala es una propuesta de solución.
- Las soluciones deben codificarse de una forma que resulte relativamente fácil de implementar en una computadora.

Para diseñar un AG es necesario codificar una solución del espacio de búsqueda real en una solución del espacio de búsqueda del AG. Esto implica una transformación, entre ambos espacios de tal forma que la codificación no admita duplicación de soluciones. Por otro lado, como apunta (Goldberg, 1989), una solución debe ser codificada en la forma más natural.

Cada problema tiene asociado una forma de representación que mejor se adapta para llevar a cabo el proceso evolutivo. La elección de una representación conveniente, generalmente la más natural, conduce a un mejor tratamiento de los individuos que forman la población.

3.2 Creación de la Población Inicial

Existen varias alternativas de creación de la población inicial: se puede comenzar con una población generada en forma aleatoria, lo cual puede implicar la existencia de individuos no válidos, en caso de problemas con restricciones. Otra alternativa consiste en sembrar la población utilizando la salida de algún algoritmo que incluya aspectos tales como conocimiento específico del problema, diversidad de las soluciones, factibilidad de las mismas, etc.

En ciertos casos, es posible contar con algún conocimiento sobre la forma que pueden tener las soluciones y es muy conveniente hacer uso de éste. Una forma de incorporar este hecho es construir la población inicial teniendo en cuenta estas subcombinaciones, aunque a veces resulta conveniente determinar qué porcentaje de la población debe ser sembrada para que el AG trabaje aprovechando esta información sin provocar problemas, por ejemplo de convergencia prematura.

Una buena población inicial resulta en un buen comienzo siempre y cuando se asegure la diversidad genética en la población.

3.3 Función de Evaluación o Función de Adaptabilidad (*Fitness*)

La función de adaptabilidad o aptitud mide (cuantifica) la calidad de la solución. En ella está contenida la principal fuente de conocimiento específico del problema y debe medir las diferencias en la calidad de las soluciones.

En los métodos de computación evolutiva la función de evaluación sirve no sólo como nexo entre el problema y el algoritmo, sino que mide la calidad de las soluciones: los mejores individuos tienen mayores probabilidades de supervivencia y reproducción. Por lo tanto es esencial definir una función de adaptabilidad que caracterice al problema con precisión.

En la mayoría de los casos, el proceso de selección de una función de adaptabilidad parece ser directo, sin embargo tal proceso puede ser más complejo cuando se trabaja con soluciones factibles y no factibles.

3.4 Soluciones Factibles y no Factibles: Manejo de las Restricciones del Problema.

Los algoritmos evolutivos, tal como están descritos, no contemplan la resolución de problemas con restricciones. Sin embargo los problemas del mundo real casi siempre están sujetos a restricciones las cuales pueden ser de igualdad, desigualdad, lineales y/o no lineales.

Para considerar la resolución del problema restringido planteado es necesario implementar estrategias que permitan el manejo de las restricciones.

Las estrategias de manejo de restricciones utilizando AG's puede clasificarse en (Gen, 1996):

1. Estrategias de rechazo: Dentro de esta categoría la estrategia de pena de muerte ha sido una opción común en varias técnicas evolutivas. El método consiste en eliminar las soluciones no factibles de la población. Produce buenos resultados si el espacio de búsqueda es convexo, esto es, que sea un conjunto en el cual se puede ir de cualquier punto a cualquier otro en vía recta, sin salir del mismo, y constituye una parte razonable del espacio de búsqueda total.

2. Estrategias de Reparación: Consiste en tomar una solución no factible y generar una factible a través de algún procedimiento de modificación o enmienda. Esta técnica es muy dependiente del problema particular y se han reportado desde casos de muy exitosa aplicación, hasta ejemplos en los cuales reparar un individuo no factible se transforma en un problema tan complejo como el original (Michalewicz, 1996).

3. Estrategias de penalización: Es un enfoque muy común, principalmente en AG. Transforma el problema restringido en un problema no restringido penalizando las soluciones (x_i) no factibles. Esto se realiza adicionando un término a la función de adaptabilidad, que depende del grado de violación de las restricciones (Goldberg, 1989):

$$F_i = f(x_i) + RQ(x_i) \dots\dots\dots(3.2)$$

Donde f representa la función objetivo, Q tiene en cuenta las violaciones al conjunto de restricciones y R es un coeficiente de penalización. Q vale 0 si no hay violación de ninguna restricción y toma un valor positivo en el caso contrario (considerando minimización). En

general Q es una función compuesta por un conjunto de funciones de penalización que miden el grado de violación de cada una de las restricciones impuestas al problema.

Otra alternativa es donde se utiliza la siguiente expresión para la función de fitness (Deb, 2000):

$$F(x_i) = \begin{cases} f(x_i) & \text{si } x_i \text{ es factible} \\ f_{\max} + Q(x_i) & \text{si } x_i \text{ no es factible} \end{cases} \dots\dots\dots(3.3)$$

Donde f_{\max} es el valor máximo de la función objetivo sobre todos los individuos factibles de la población.

Se han propuesto diversas funciones de penalización, una de ellas (Homaifar, 1994) supone que para todas las restricciones se establece una familia de intervalos en los cuales se determina un coeficiente de penalización apropiado asignando para cada restricción un nivel de violación. Para mayores grados de violación se asigna un coeficiente mayor. La función de aptitud de un individuo está dada por la siguiente expresión.

$$F(x) = f(x) + \sum_{j=1}^m R_{ij} f_j^2(x) \dots\dots\dots(3.4)$$

Donde R_{ij} es el coeficiente de penalización en el nivel i de la restricción j (evaluada a través de la función f_j^2 y m es el número de restricciones al problema. El principal problema de esta propuesta es el exceso de parametrización que involucra.

Modificación de los operadores genéticos: En esta estrategia los operadores de mutación y cruzamiento se diseñan en forma ad-hoc para un problema particular con el fin de preservar la factibilidad de cada solución. La dificultad de esta estrategia es diseñar los operadores de forma tal que se preserve la factibilidad de la solución.

3.5 Mecanismos de Selección de Padres

Como ya se mencionó, el algoritmo hace evolucionar sucesivas generaciones de individuos hasta obtener la solución óptima. La creación de una nueva generación a partir de los operadores genéticos es un punto muy importante e involucra al proceso de selección. Este proceso intenta simular la selección natural de los individuos vivos y es el encargado de seleccionar los padres de la próxima generación (los que sobrevivirán) en función de su *calificación*. De esta forma, los mejores individuos pasarán a la próxima generación sus características genéticas. La clave de la selección es que los más aptos tengan mayor probabilidad de recombinarse y contribuir con sus hijos a la próxima generación.

Una parte fundamental del funcionamiento de un algoritmo genético es, sin lugar a dudas, el proceso de selección de candidatos a reproducirse. En un algoritmo genético este proceso de selección suele realizarse de forma probabilística (es decir, aún los individuos menos aptos tienen una cierta oportunidad de sobrevivir).

Lo ideal sería que al comienzo del AG, la selección debería asegurar una amplia exploración del espacio de búsqueda (presión selectiva baja), mientras que en las últimas etapas sería deseable una explotación marcada de las regiones más prometedoras (presión selectiva alta). Este conflicto entre exploración y explotación ha dado origen a varios métodos de selección de individuos de una población para su supervivencia y reproducción.

Entre los métodos de selección más usados pueden mencionarse las siguientes:

1. Selección Proporcional
2. Selección por Jerarquía (Ranking)
3. Selección por Torneo

3.5.1 Métodos de Selección Proporcional

La selección proporcional es una estrategia donde la probabilidad de ser padres es proporcional al *fitness* de cada individuo. Hay dos estrategias propuestas para este tipo de selección.

3.5.1.1 Método de la Ruleta

Esta técnica de selección proporcional (Jong,1975), ha sido el método más comúnmente usado en los orígenes de los algoritmos genéticos. El algoritmo, simple aunque ineficiente, tiene una complejidad $O(n^2)$.

Una ruleta honesta, consta de ranuras en una de las cuales caerá la bolita. Eso asegura que todos los números tienen la misma probabilidad de ser elegidos. Pero si el ancho de cada ranura fuera diferente, los números que identifican a las ranuras más anchas tendrán mayor probabilidad de ser elegidos que los que pertenecen a ranuras estrechas. Entonces si lo que se busca es que la probabilidad de que un cromosoma sea elegido como padre sea proporcional a su *calificación*, el ancho de cada ranura será justamente proporcional a la medida de aptitud.

En esta particular ruleta, el ancho de cada ranura es el aporte del *fitness* de un cromosoma i , (F_i) con relación a la sumatoria de los *fitness* de todos los individuos de la población (FT). Si la población tiene N individuos entonces

$$FT = \sum_{i=1}^N F_i \dots\dots\dots(3.5)$$

y la probabilidad de que un cromosoma i sea seleccionado estaría dada por

$$P_i = \frac{F_i}{FT} \dots\dots\dots(3.6)$$

Entonces, la simulación del lanzamiento de la bolita se consigue generando un número aleatorio entre 0 y FT además de utilizar los valores de *fitness* acumulados se determina en qué ranura cae y por lo tanto cuál individuo es seleccionado para procrear.

El inconveniente de la selección proporcional de la ruleta es que en las primeras generaciones del AG, la presencia de individuos con un valor de adaptabilidad muy bueno provoca que el mecanismo de selección proporcional seleccione de preferencia a estos superindividuos provocando así la convergencia temprana.

3.5.1.2 Selección Universal Estocástica.

La selección universal estocástica, (Baker, 1985) tiene como objetivo minimizar la mala distribución de los individuos en la población en función de los valores esperados. Se puede

pensar como un peine de dientes equidistantes en el cual el primero de dichos dientes tiene un valor aleatorio, mientras que los demás quedan determinados por aquél. De esa manera se evita el copamiento rápido de un individuo con *fitness* muy alto en relación al resto de la población.

La complejidad del algoritmo es $O(n)$. Dadas sus características puede tener los siguientes problemas: puede aún ocasionar convergencia prematura y hacer que los individuos más aptos se multipliquen muy rápidamente. Por otra parte no resuelve el problema más serio de la selección proporcional, o sea, la imprecisión entre los valores esperados y los números de copias de cada individuo que son realmente seleccionados (Coello Coello, 2003).

3.5.2 Método de Selección por Jerarquías

Este método fue propuesto (Baker, 1985) para evitar la convergencia prematura en las técnicas de selección proporcional. El objetivo de esta técnica es disminuir la presión de selección. En este caso, se presenta la técnica de jerarquías lineales, pero es posible también usar jerarquías no lineales, aunque la presión de selección sufre cambios más abruptos al usarse esta última.

Los individuos se clasifican en base a su aptitud (*fitness*) en orden decreciente, y se le asigna una probabilidad de selección en función de su rango (o jerarquía) sin tener en cuenta su *fitness* original. El uso de jerarquías hace que no se requiera escalar la aptitud, puesto que las diferencias entre las aptitudes absolutas se diluyen. Asimismo, las jerarquías previenen la convergencia prematura.

En el ranking lineal, la probabilidad de selección asignada a los individuos es proporcional al rango k de los mismos: el mejor individuo tiene rango 1 y el peor, rango $N > 1$. La probabilidad de que un individuo i de rango k sea seleccionado está dado por la ecuación 3.7.

$$P_s(i) = \frac{1}{N} \left[\eta_{\max} - 2(\eta_{\max} - 1) \frac{k - 1}{N - 1} \right] \dots\dots\dots(3.7)$$

El parámetro η_{\max} representa el número esperado de veces que el mejor individuo será seleccionado. Teniendo en cuenta que

$$\sum_{i=1}^N P_s(i) = 1 \dots\dots\dots(3.8)$$

puede demostrarse que $1 \leq \eta_{\max} \leq 2$. Por lo tanto la elección de un valor particular de η_{\max} sirve para controlar la presión de selección. Baker (1985) recomendó $\eta_{\max} = 1.1$.

El uso de jerarquías requiere que se ordene toda la población (una operación cuyo costo puede volverse significativo en poblaciones grandes).

3.5.2.1 Selección Mediante Torneo

Los métodos de selección proporcional antes descritos requieren de dos pasos a través de toda la población en cada generación: calcular la aptitud media y calcular el valor esperado de cada individuo.

Una alternativa a los métodos anteriores es la selección por torneo (Bickle y co., 1996), donde un individuo necesita ganar una competencia entre un conjunto de individuos seleccionados aleatoriamente.

En un k -torneo el mejor de k individuos es seleccionado en forma determinística, aunque ocasionalmente puede ser utilizada una selección estocástica.

La selección mediante torneo es similar a la de jerarquías en términos de la presión de selección, pero es computacionalmente más adecuada para implementarse en paralelo. La idea básica del método es seleccionar p candidatos de la población que competirán entre sí sobre la base de sus valores de aptitud. Con una probabilidad determinada de antemano (que puede ser 1, en cuyo caso se dice que el torneo es determinístico), el ganador de la competencia es seleccionado como padre.

La complejidad del algoritmo es $O(n)$. Puede introducir una presión de selección muy alta porque a los individuos menos aptos no se les da oportunidad de sobrevivir. No requiere escalamiento de la función de aptitud (usa comparaciones directas) y es una técnica eficiente y fácil de implementar.

3.6 Operadores Genéticos

Una vez seleccionado el conjunto de padres que generarán descendencia es necesario continuar con una fase muy importante en el proceso evolutivo en la cual los individuos seleccionados intercambian material genético o alteran algunos de sus genes.

Los individuos de una población $P(t)$ deben generar descendencia transmitiendo sus características genéticas a sus hijos. Para ello deberá contarse con operadores que permitan dicha transformación y que necesariamente estarán influidos por el tipo de representación y de problema a resolver. Dos operadores utilizados en algoritmos genéticos son los operadores de cruzamiento y mutación.

3.6.1 Operador de Cruzamiento

En forma concisa puede considerarse que el cruzamiento permite generar hijos a partir de padres seleccionados. Formalmente el cruzamiento podría definirse como una función

$$C : S^q \rightarrow S^r \quad C(x_1^t, \dots, x_q^t) \rightarrow C(x_1^t, \dots, x_r^t) \dots\dots\dots(3.9)$$

Donde q es la cantidad de padres r es la cantidad de hijos, y x_i^t es el cromosoma i de la población P^t antes del cruzamiento.

El cruzamiento o recombinación produce nuevos individuos adoptando la información contenida en dos o más padres. Esto se hace combinando los valores de las variables que definen los padres. Dependiendo de la forma de representación de las variables se deben utilizar diferentes métodos. Hay diversos métodos de recombinación, que dependen del tipo de variable utilizado.

A continuación se describen únicamente los métodos de cruzamiento para representación binaria. Sin embargo la idea básica puede ser extrapolada a representaciones decimales o alfa numéricas.

Durante la recombinación de variables binarias se intercambian sólo partes del individuo y dependiendo del número de partes de intercambio se definen las técnicas de cruzamiento.

Hay tres técnicas básicas de cruzamiento, comúnmente utilizadas con representación de cromosomas mediante cadenas binarias:

- Cruzamiento de un punto
- Cruzamiento de dos o más puntos
- Cruzamiento uniforme

3.6.1.1 Cruzamiento de un Punto

En esta técnica (Holland, 1975), se selecciona aleatoriamente un punto de cruce.

$$k \in [1, 2, \dots, N], \quad N = \text{número de variables de un individuo}$$

Luego las variables se intercambian entre los individuos a partir de este punto, de lo cual se obtienen dos descendientes. La figura 3.2 muestra el proceso.

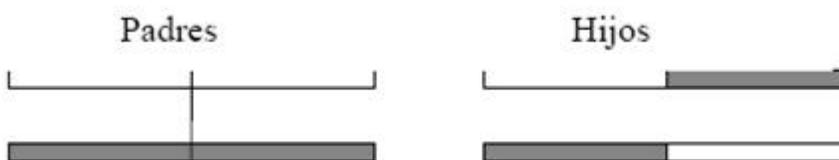


Figura 3.2. Cruzamiento en un Punto

Como ejemplo se puede considerar dos individuos de 11 variables binarias cada uno:

individuo 1: 0 1 1 1 0 0 1 1 0 1 0
 individuo 2: 1 0 1 0 1 1 0 0 1 0 1

El punto elegido de cruzamiento es 5, entonces los hijos generados son:

descendiente 1: 0 1 1 1 0 | 1 0 0 1 0 1
 descendiente 2: 1 0 1 0 1 | 0 1 1 0 1 0

Puede demostrarse, por ejemplo, que hay varios esquemas que no pueden formarse bajo esta técnica de cruzamiento. Michalewicz define un esquema como la representación de todos los *strings* (un subconjunto del espacio de búsqueda) que se ajusta con todas las otras posiciones distintas de "*". Es decir, es una plantilla que permite la exploración de las similitudes entre los cromosomas, esto se construye introduciendo el símbolo "*" en representación de un gen en la cadena de bits de los individuos. Así por ejemplo para individuos que tienen cadenas binarias de longitud 3, el esquema (***) representaría a todos los individuos de la población. De igual forma el esquema (10*) representaría al individuo (100) y al (101). De esta manera, lo que procesa un AG son los esquemas y la población inicial evoluciona generación tras generación, donde los esquemas más aptos irán sobreviviendo, mientras que los menos aptos irán desapareciendo. Por ejemplo, en los esquemas siguientes:

H1 = 11*****1
 H2 = *****11**

Si se aplica cruzamiento de un punto a estos 2 esquemas, no hay manera de formar una instancia del esquema:

$$H = 11^{**}11^{*}1$$

El cruzamiento de un punto destruye esquemas en los que la longitud de definición es alta. Esto produce lo que se denomina sesgo posicional: los esquemas que pueden crearse o destruirse por el cruzamiento dependen fuertemente de la localización de los bits en el cromosoma (Eshelman, 1989). El problema fundamental del cruzamiento de un punto es que presupone que los bloques constructores son esquemas cortos y de bajo orden, y cuando esto no sucede (p. e., con cadenas largas), puede proporcionar resultados no apropiados.

Obviamente, las aplicaciones del mundo real requieren cadenas largas lo que hace que este cruzamiento no se use comúnmente en dichos problemas. El cruzamiento de un punto trata también preferentemente algunas posiciones del cromosoma, como por ejemplo los extremos de una cadena.

El cruzamiento de un punto suele preservar también los *hitchhikers*, que son bits que no forman parte del esquema deseado, pero que debido a su similitud con ellos gozan de los beneficios del cruzamiento.

3.6.1.2 Cruzamiento de dos o más Puntos

En esta técnica se seleccionan dos puntos de cruce en forma aleatoria y los intercambios de las variables suceden alrededor de esos dos puntos y se obtienen también dos nacimientos. En la figura 3.3 puede verse el proceso.

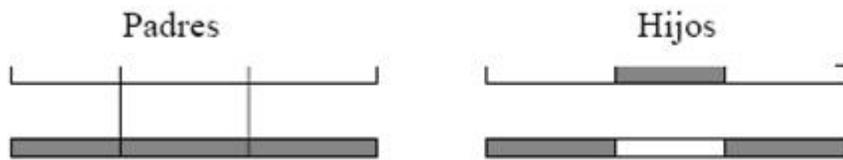


Figura 3.3. Cruzamiento de dos o mas Puntos

De Jong (1975) fue el primero en implementar este cruzamiento, como una extensión del cruzamiento de un punto.

Mediante el cruzamiento de dos puntos se logran reducir los efectos disruptivos (o destructivos) propios del cruzamiento, razón por la cual es usado con frecuencia. En este sentido, no existe consenso en torno al uso de cruzamiento de más puntos de cruce. Los estudios empíricos al respecto proporcionan resultados que no resultan concluyentes respecto a las ventajas o desventajas de usar dichos valores. En general, sin embargo, es aceptado que el cruzamiento de dos puntos es mejor que el cruzamiento de un punto.

3.6.1.3 Cruzamiento Uniforme

El cruzamiento de uno o dos puntos define los puntos de cruce donde cada individuo puede ser cortado. El cruzamiento uniforme generaliza este esquema haciendo que cada punto tenga un potencial de cruce. En la figura 3.4 puede verse el proceso.

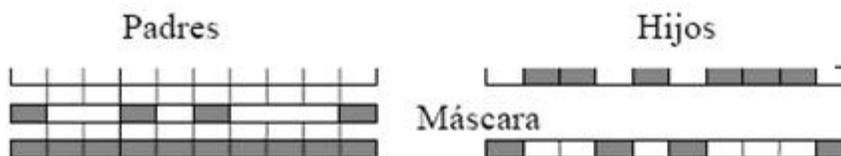


Figura 3.4. Cruzamiento Uniforme

Esto puede lograrse mediante una expresión lógica, generando una máscara en forma aleatoria del mismo largo que los cromosomas y procediendo de la siguiente manera: si el bit j de la máscara es 1 en el hijo se copia el bit del padre en uno de los hijos y el de la madre en el otro hijo. En caso contrario la operación se invierte.

$$H = PM_k + MM_k$$

Donde:

H es el descendiente
 P es el padre
 M es la madre
 M_k es la máscara

Como ejemplo es posible considerar dos individuos de 11 variables binarias cada uno:

$$P = [0\ 1\ 1\ 1\ 0\ 0\ 1\ 1\ 0\ 1\ 0]$$

$$M = [1\ 0\ 1\ 0\ 1\ 1\ 0\ 0\ 1\ 0\ 1]$$

Las variables del padre que contribuye se eligen aleatoriamente con igual probabilidad. Entonces el descendiente 1 se produce tomando el bit del padre 1 si el bit de la máscara correspondiente es 1 o el bit del padre 2 si el bit de la máscara es 0, el descendiente 2 se crea usando la máscara inversa. Siguiendo con el ejemplo, si la máscara está dada por:

$$M_k = [0\ 1\ 1\ 0\ 0\ 0\ 1\ 1\ 0\ 1\ 0]$$

Después del cruce los nuevos individuos son:

$$H_1 = [1\ 1\ 1\ 0\ 1\ 1\ 1\ 1\ 1\ 1\ 1]$$

$$H_2 = [0\ 0\ 1\ 1\ 0\ 0\ 0\ 0\ 0\ 0\ 0]$$

El cruce uniforme y el cruce multipunto han sido desarrollados para reducir el sesgo asociado con la longitud de la representación binaria usada y la codificación particular para un conjunto de parámetros dado.

3.6.1.4 Sesgos del Cruzamiento

El "sesgo" del cruce se refiere a las tendencias de este operador a favorecer o no un cierto tipo de búsqueda. Realmente, la búsqueda aleatoria es la única que no presenta ningún tipo de sesgo, por lo que es de esperarse que cualquier operador heurístico como el cruce sí lo tenga presente.

De hecho, se ha determinado que se requiere de algún tipo de sesgo para que una técnica de búsqueda sea efectiva (Mitchell, 1980). En algoritmos genéticos, se suelen considerar 2 tipos de sesgo para el cruce: Distribucional y Posicional.

El sesgo distribucional se refiere al número de símbolos transmitidos durante una recombinación. Asimismo, se refiere a la medida en la que algunas cantidades tienen más tendencia a ocurrir que otras. El sesgo distribucional es importante porque está correlacionado con el número potencial de esquemas de cada padre que pueden ser recombinados por el operador de cruzamiento.

El cruzamiento de un punto y el de dos puntos no tienen sesgo distribucional, más de dos puntos, sí lo tiene pero moderado; por otra parte, un cruzamiento uniforme tiene un sesgo distribucional muy fuerte.

El sesgo posicional caracteriza en qué medida la probabilidad de que un conjunto de símbolos se transmitan intactos durante la recombinación dependiendo de las posiciones relativas de los mismos en el cromosoma.

El sesgo posicional es importante porque muestra los esquemas que más probablemente se hereden de padres a hijos. Asimismo, también indica la medida en la que estos esquemas aparecerán en nuevos contextos. En este caso es posible decir que el cruzamiento de un punto tiene un fuerte sesgo posicional, además, todo parece indicar, que el cruzamiento de 2 puntos tiene también un sesgo posicional fuerte y, finalmente, el cruzamiento uniforme no tiene sesgo posicional.

3.6.1.5 Variantes del Cruzamiento

Es posible modificar diversos aspectos del cruzamiento para mejorar su desempeño. Una variante, por ejemplo, consiste en retener sólo a uno de los dos hijos producidos por un cruzamiento. Holland (1975) describió una técnica de este tipo.

Estudios empíricos han mostrado, además, que retener a los 2 hijos producidos por un cruzamiento reduce sustancialmente la pérdida de diversidad en la población (Lashon, 1982).

Otra variante muy común es la de restringir los puntos de cruzamiento a aquellas posiciones en las que los padres difieran. A esta técnica se le conoce como sustitución reducida (Lashon, 1987), y su objetivo es mejorar la capacidad del cruzamiento para producir hijos que sean distintos a sus padres.

Una alternativa interesante es la llamada cruzamiento con mezcla (Eshelman, 1989). En este caso, se aplica un operador de permutación a una parte de las cadenas de los padres antes de efectuar el cruzamiento. Después del cruzamiento, se aplica la permutación inversa a fin de restaurar el orden original de los bits.

El cruzamiento con mezcla tiene como objeto contrarrestar la tendencia del cruzamiento de puntos ($n \geq 1$) a causar con más frecuencia disrupción en los conjuntos de bits que están dispersos que en los que están juntos.

3.6.1.6 Comportamiento Deseable del Cruzamiento

Todos los operadores descritos anteriormente, siguen el principio Mendeliano de la herencia: cada gen de un hijo, es una copia de un gen heredado de alguno de sus padres.

Algunos investigadores han destacado que el énfasis del cruzamiento debe ser el poder generar todas las posibles combinaciones de bits (de longitud L) que hayan en el espacio de búsqueda del problema (Radcliffe, 1991). Dada una cierta representación binaria, ni el

cruzamiento de un punto, ni el de $n < L$ puntos son capaces de lograr esto. El cruzamiento uniforme, sin embargo, sí puede hacerlo.

Radcliffe propuso una variante a esta técnica denominada recombinación respetuosa aleatoria, se genera un hijo copiando los bits en los que sus padres son idénticos, y eligiendo luego, valores al azar para llenar las posiciones restantes.

3.6.2 Mutación

El operador de mutación también depende de la representación de los cromosomas. En el caso de representación por cadenas de bits, la mutación simplemente implica alterar bits de un cromosoma con cierta probabilidad.

La operación de mutación implica decidir, en cada posición de bit y acorde con la probabilidad de mutación, si el bit debe mutar o no.

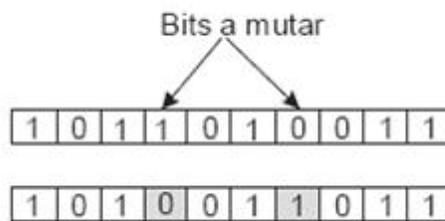


Figura 3.5. Operador Mutación

La mutación es un operador que permite la exploración de otras regiones del espacio de búsqueda y evita que el AG quede atrapado en un óptimo local. No obstante, aplicar una alta probabilidad de mutación al algoritmo puede traer como consecuencia transformarlo en uno de búsqueda aleatoria por cuanto es factible destruir buenas soluciones (que quizás produzcan como descendencia, individuos aún mejores). De hecho una probabilidad de mutación igual a la unidad implica una búsqueda totalmente aleatoria. Por esta razón, en general, se utilizan bajas probabilidades de mutación (del orden de 10^{-3} a 10^{-2}). Algunos investigadores, sin embargo, han sugerido que el usar probabilidades altas de mutación al inicio de la búsqueda, y luego decrementarlos exponencialmente, favorece el desempeño de un AG (Fogarty, 1989).

Otros autores sugieren que

$$P_m = \frac{1}{L} \dots\dots\dots(3.9)$$

(donde L es la longitud de la cadena cromosómica) es un límite inferior para la probabilidad óptima de mutación (Bäck, 1993).

También se menciona la mutación heurística, (Gen, 2000) que realiza un procedimiento más elaborado que es similar a algunos algoritmos básicos de búsqueda tabú (Glover, 2002). Se selecciona un conjunto de genes en forma aleatoria a partir de los cuales se generan todas las permutaciones posibles de dicho conjunto (cada una de estas permutaciones son soluciones vecinas a la primera). Finalmente se evalúan todos los vecinos y se toma el mejor.

3.6.3 Cruzamiento Vs. Mutación

El cruzamiento uniforme es mejor explorando que el cruzamiento de un punto. Si, por ejemplo se consideran los cromosomas:

$$\begin{array}{l}
 P1 = 1 * * * * 1 \\
 \text{y} \\
 P2 = 0 * * * * 0
 \end{array}$$

en los cuales los asteriscos simbolizan cualquier valor para el gen, mientras que el primero y el último tienen los valores asignados y fijos, el cruzamiento uniforme producirá individuos del esquema *********, mientras que el cruzamiento de un punto producirá individuos de los esquemas **1****0** y **0****1**.

Por otra parte si se analiza el poder exploratorio de la mutación, es posible distinguir tres situaciones:

- Si la probabilidad de mutación es cero, no hay alteración alguna.
- Si es uno, la mutación crea siempre complementos del individuo original.
- Si es 0.5, hay una alta probabilidad de alterar fuertemente el esquema de un individuo.

En otras palabras, es posible controlar el poder de alteración de la mutación y su capacidad de exploración puede hacerse equivalente a la explotación realizada por el cruzamiento. Por ejemplo, dados:

$$\begin{array}{l}
 P1 = 10**** \\
 P2 = 11****
 \end{array}$$

El cruzamiento producirá sólo individuos del esquema **1*******.

El primer "1" en el esquema está garantizado (sin importar qué tipo de cruzamiento se use), porque es común en los esquemas de ambos padres. La mutación, sin embargo, no respeta necesariamente este valor.

El cruzamiento "preserva" los alelos (se denomina así a cada lugar del *string* que representa un cromosoma, por ejemplo un cromosoma de longitud 10 tiene 10 alelos) que son comunes en los 2 padres. Esta preservación limita el tipo de exploración que el cruzamiento puede realizar. Esta limitación se agudiza conforme la población pierde diversidad, puesto que el número de alelos comunes se incrementaría.

Cuando se busca localizar el óptimo global de un problema, la mutación puede ser más útil que el cruzamiento. Si lo que interesa es ganancia acumulada (el objetivo original del AG), el cruzamiento es entonces preferible.

3.7 Elitismo

Se ha explicado que a partir de una generación dada se obtiene la siguiente por medio de los operadores descritos. Sin embargo, los mejores individuos, si bien son los padres de los que forman la próxima generación, pueden quedar excluidos. El elitismo tiende a evitar dicha situación. Especificando la cantidad de individuos de elite, se puede permitir el paso de algunos de ellos a la siguiente generación. De esta manera se asegura que la siguiente generación tendrá siempre al menos un individuo de igual o mejor aptitud (*fitness*) que en la

anterior. El procedimiento es copiar, antes de comenzar a aplicar los operadores genéticos, los mejores k individuos de una población a la siguiente. k es un parámetro del AG.

3.8 Modelos de Población

Un modelo de población puede ser distinguido de otro observando la estrategia de selección de padres y la definición del conjunto de apareamiento. Se pueden definir tres modelos de población.

Modelo global o panmítico. La selección tiene lugar en la población completa. Esto significa que cualquier individuo de la población es candidato y puede ser seleccionado para la producción de la descendencia.

Modelo regional o de islas. La selección de padres se realiza en partes de la población aisladas unas de otras, las cuales son denominadas subpoblaciones. Dentro de cada subpoblación la selección es irrestricta (similar al modelo global). La interacción entre islas se realiza mediante migración de individuos.

Modelo de vecindades. En este modelo la selección de padres se realiza en una vecindad local, cuyo tamaño está dada por la cantidad de vecinos de cada individuo. La interacción entre vecindades se garantiza a través de la pertenencia de cada individuo a más de una vecindad.

3.8.1 Modelo Global (Panmítico)

El modelo global no subdivide la población sino que la considera en forma completa. Durante el proceso de selección, un individuo seleccionado tiene la posibilidad de aparearse con cualquier otro individuo de la población. Aunque estos esquemas, tales como selección estocástica con reemplazo, son ampliamente utilizados, no tienen buen desempeño en algunos problemas con búsquedas de genotipos "exitosos" en espacios de gran tamaño y/o multimodales (Collins, 1992). Sucede que la población es incapaz de mantener genotipos radicalmente diferentes con buen *fitness* debido al problema de convergencia prematura.

3.8.2 Modelo Regional

El modelo regional (o modelo de migración) divide la población en múltiples subpoblaciones. Estas se desarrollan durante varias generaciones independientemente de las demás (tiempo de aislamiento). Después de este tiempo, algunos de los individuos se distribuyen entre las subpoblaciones (migración).

La cantidad de intercambios de individuos (tasa de migración) y el método de selección de los individuos que migrarán determinarán cuánto puede variar la diversidad genética en la subpoblación y el intercambio de información entre subpoblaciones.

Es posible la implementación de algoritmos paralelos aplicados sobre un modelo regional de población. Más aún, en algunos casos, para una computadora de una única CPU, la implementación de un algoritmo paralelo en forma serial (pseudo paralelo) puede obtener mejores resultados (el algoritmo encuentra el óptimo global con menor cantidad de evaluaciones de la función de aptitud) que utilizando el modelo panmítico.

En cuanto a los criterios que pueden adoptarse para seleccionar los candidatos a ser migrados, puede utilizarse una selección aleatoria de los mismos o bien hacer uso de una función que dependa del *fitness* para favorecer la migración de los mejores individuos.

Existen muchas posibilidades para la estructura de migración de individuos entre subpoblaciones. A continuación se esbozan algunas alternativas:

- Entre todas las subpoblaciones (formando una red con topología de malla completa, sin restricciones). En este caso cualquier subpoblación puede migrar individuos a cualquier otra. La Figura 3.6 muestra el esquema de este tipo de migración.

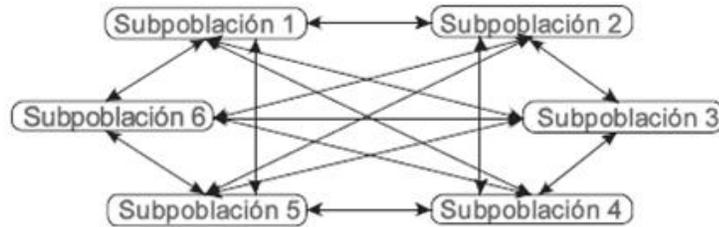


Figura 3.6. Topología de Migración Irrestricta

- Topología en anillo. Las subpoblaciones se organizan formando un anillo, como se muestra en la Figura 3.7 los individuos migran desde cada subpoblación a la siguiente. Por ejemplo, en el esquema más básico de migración en anillo, en un conjunto de 6 subpoblaciones, los individuos de la subpoblación 6 migran sólo a la subpoblación 1, los de la subpoblación 1 sólo lo hacen a la 2 y así sucesivamente.

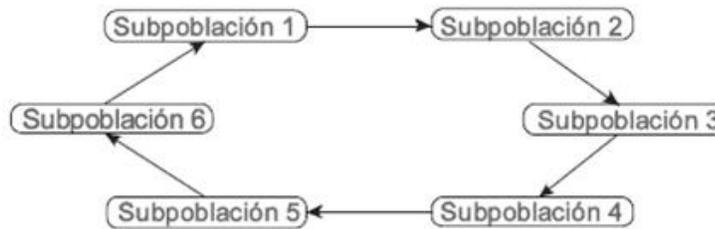


Figura 3.7. Topología de Migración de Anillo – Distancia 1

- Topología de vecindad. Es una estrategia similar a la topología en anillo. Las subpoblaciones son organizadas en grupos llamados vecindades. La migración está permitida sólo entre subpoblaciones vecinas aunque en este caso la migración puede ocurrir en cualquier dirección. Para cada subpoblación el posible inmigrante está determinado de acuerdo al método de selección elegido desde una subpoblación adyacente. Un ejemplo se muestra en la Figura 3.8.

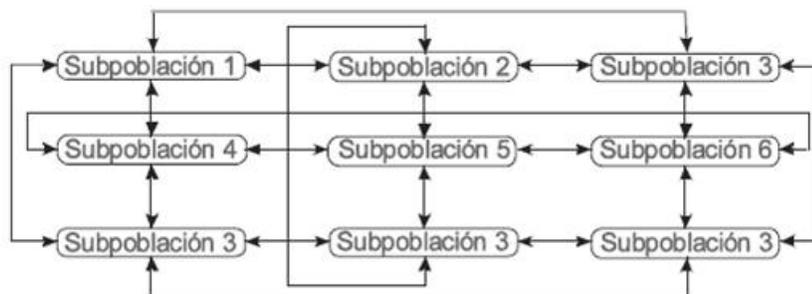


Figura 3.8. Topología de Migración entre Vecindades (en este caso: Malla de 2 Dimensiones)

Los resultados reportados (Lohman, 1991) indican que los algoritmos evolutivos con multipoblación obtienen mejores resultados que con una población única.

3.8.3 Modelo de Difusión Local o de Vecindades

Este modelo maneja cada individuo separadamente y selecciona su compañero de apareamiento en una vecindad por selección local. En consecuencia, con este proceso la información se difunde a través de la población durante la búsqueda gracias a la pertenencia de un individuo a más de una vecindad.

Para trabajar con poblaciones estructuradas según un modelo de difusión local se utiliza la técnica denominada selección local. En esta técnica, cada individuo reside en un ambiente reducido o vecindad, y éste interactúa sólo con individuos dentro de esa región. Las vecindades están definidas por la estructura en la cual la población está distribuida y puede verse como grupos de potenciales compañeros de apareamiento.

El conjunto de apareamiento se conforma de la siguiente manera:

Utilizando algún algoritmo de selección se incorporan los "padres" al *pool*, el cual conjunto completo de individuos en una población. Ahora la vecindad está definida en el entorno de cada padre seleccionado.

El compañero de apareamiento ("madre") se selecciona dentro de cada vecindad con algún criterio predefinido (por ejemplo el mejor individuo dentro de la vecindad, con una probabilidad proporcional a su función de aptitud, etc.).

La estructura de la vecindad puede ser:

- Lineal
- Bidimensional
- Tridimensional
- Combinada: cualquier combinación de las estructuras anteriores.

La distancia entre los posibles vecinos junto con la estructura determina el tamaño de la vecindad, el cual a su vez determina la velocidad de propagación de información entre los individuos de la población. Un tamaño de vecindad grande significa un incremento en la velocidad de propagación de la información y una disminución de la diversidad. De hecho, si el tamaño de la vecindad coincide con el tamaño de la población se está en presencia del modelo panmítico.

3.8.4 Reinserción

Una vez que los descendientes han sido producidos por selección, cruzamiento y mutación de individuos de la población original, es posible determinar el *fitness* correspondiente. Para ello se deben tener en cuenta las siguientes consideraciones: Si se han generado menos descendientes que el tamaño de la población original, éstos deben ser reinsertados de tal forma que este último valor no se altere. Por otra parte, si no se utilizan todos los descendientes de la nueva generación, o se han generado más hijos que el tamaño de la población original, es necesario utilizar un esquema de reinserción.

El esquema de reinserción queda determinado por el tipo de selección utilizado. Si la selección es local entonces es necesario aplicar un método de reinserción igualmente local.

Para los otros tipos de selección la reinserción de descendientes sigue un esquema llamado reinserción global. A continuación se realiza una descripción de ambos esquemas de reinserción.

3.8.4.1 Reinserción Global

Existen diferentes variantes de reinserción global. Estas pueden ser:

- Producir tantos descendientes como cantidad de padres, reemplazándolos a todos estos por sus hijos (reinserción pura)
- Producir menos descendientes que padres, reemplazándolos aleatoriamente (reinserción uniforme).
- Producir menos descendientes que padres, reemplazando los peores de estos últimos (reinserción elitista).
- Producir más descendientes que los necesarios y reinsertar los mejores (reinserción basada en *fitness*).

La reinserción pura es el esquema de reinserción más simple, cada individuo vive sólo una generación. Este algoritmo se utiliza en los AG's simples, pero tiene la desventaja de que un muy buen individuo puede ser reemplazado sin dejar descendencia y su información se pierda.

3.8.4.2 Reinserción Local

Para la selección de padres a ser reemplazados y de descendiente a reinsertarse se pueden seguir las siguientes variantes:

- Insertar todos los descendientes y reemplazar los individuos en la vecindad en forma aleatoria.
- Insertar todos los descendientes y reemplazar los individuos más débiles de la vecindad.
- Insertar un descendiente que sea más apto que el individuo más débil en la vecindad, eliminando a este último.
- Insertar un descendiente que sea más apto que el individuo más débil en la vecindad, y eliminar aleatoriamente a uno de los padres.
- Insertar la descendencia en el lugar de los padres sólo si aquella es más apta que éstos.

El elitismo combinado con reinserción basado en *fitness* es el método que se recomienda Pohlheim (1999). A su vez se pueden diferenciar dos esquemas de selección: en uno de ellos, en cada generación se reemplaza una cierta cantidad de padres (los menos adecuados) por los descendientes más aptos. Este esquema implementa una selección entre descendientes antes de insertarlos en la población (es decir antes que puedan participar en el proceso de reproducción). Por un lado, el mejor individuo puede vivir por muchas generaciones, pero por otra parte no hay un control acerca de que los padres sean reemplazados por mejores o peores hijos. El otro esquema es realizar una competencia entre los padres y los descendientes para generar una población con los más aptos de los dos conjuntos.

3.9 Parámetros de los Algoritmos Evolutivos

Para que un AG pueda funcionar, es necesario definir un conjunto de valores llamados parámetros. Los más importantes son:

- El tamaño de la población.
- El número máximo de iteraciones.
- La longitud de los individuos.
- La probabilidad de cruzamiento.
- La probabilidad de mutación.

Además, los que son característicos de cada método en particular, como por ejemplo el coeficiente de la función de penalización, el tamaño de la vecindad en poblaciones estructuradas, etc.

Si bien no existen criterios definitivos para la selección de los valores a asignar al conjunto de parámetros, pueden encontrarse en la literatura ciertas recomendaciones de carácter general y otras específicas asociadas con la probabilidad de cruzamiento $P(C)$ y la probabilidad de mutación $P(M)$.

La probabilidad de cruzamiento se puede definir de diferentes formas según lo que interese buscar. Puede ser la relación entre el número esperado de hijos producidos en cada generación y el tamaño de la población (Bäck, 1997). También puede definirse como el número esperado de cruzamientos en cada generación, de esta forma lo que se controla es el número de operaciones de cruzamiento independientemente del número de hijos que se crean en cada operación.

La probabilidad de mutación está relacionada con el número esperado de bits a mutar en cada generación. Sin embargo esta operación puede variar dependiendo de la aplicación específica.

El tamaño de la población (N) constituye un parámetro de gran importancia en el diseño de un AG. Puede decirse que en general valores pequeños de N conducen a una convergencia temprana del algoritmo, en tanto que valores muy grandes exigen un esfuerzo computacional alto sin lograr un mejor desempeño.

El número máximo de generaciones T , es un criterio de detención posible del algoritmo y los valores utilizados en la literatura varían en un rango muy amplio. Otras condiciones de terminación utilizadas son por ejemplo:

Medir el progreso realizado por el algoritmo en un número predefinido de generaciones y detener la búsqueda cuando tal progreso es menor que algún valor dado.

Correr el algoritmo hasta que la población se haya estabilizado, es decir, cuando todos o la mayoría de los individuos tengan la misma aptitud (Michalewicz, 1996), etc.

3.10 Ventajas de los Algoritmos Genéticos

La principal ventaja es que los algoritmos genéticos son intrínsecamente paralelos. La mayoría de los otros algoritmos son en serie y sólo pueden explorar el espacio de soluciones hacia una solución en una dirección al mismo tiempo, y si la solución que descubren resulta subóptima, no se puede hacer otra cosa que abandonar todo el trabajo hecho y empezar de

nuevo. Sin embargo, ya que los AG's tienen descendencia múltiple, pueden explorar el espacio de soluciones en múltiples direcciones a la vez. Si un camino resulta ser un callejón sin salida, pueden eliminarlo fácilmente y continuar el trabajo en caminos más prometedores, dándoles una mayor probabilidad en cada ejecución de encontrar la solución.

Sin embargo, la ventaja del paralelismo va más allá de esto. Considere lo siguiente: todas las cadenas binarias (cadenas de ceros y unos) de 8 dígitos forman un espacio de búsqueda, que puede representarse como 2^8 (donde * significa "0 ó 1"). La cadena 01101010 es un miembro de este espacio. Sin embargo, también es un miembro del espacio 0^7* , del espacio 01^7* , del espacio 0^6**0 , del espacio $0^5*1*1*1*$, del espacio 10^*01**0 , etcétera. Evaluando la aptitud de esta cadena particular, un algoritmo genético estaría sondeando cada uno de los espacios a los que pertenece. Tras muchas evaluaciones, iría obteniendo un valor cada vez más preciso de la aptitud media de cada uno de estos espacios, cada uno de los cuales contiene muchos miembros. Por tanto, un AG que evalúe explícitamente un número pequeño de individuos está evaluando implícitamente un grupo de individuos mucho más grande, el AG puede dirigirse hacia el espacio con los individuos más aptos y encontrar el mejor de ese grupo. En el contexto de los algoritmos evolutivos, esto se conoce como teorema del esquema, y es la ventaja principal de los AG's sobre otros métodos de resolución de problemas (Holland 1992, Mitchell 1996, Goldberg 1989).

Debido al paralelismo que les permite evaluar implícitamente muchos esquemas a la vez, los algoritmos genéticos funcionan particularmente bien resolviendo problemas cuyo espacio de soluciones potenciales es realmente grande, demasiado vasto para hacer una búsqueda exhaustiva en un tiempo razonable. La mayoría de los problemas que caen en esta categoría se conocen como "no lineales". En un problema lineal, la aptitud de cada componente es independiente, por lo que cualquier mejora en alguna parte dará como resultado una mejora en el sistema completo. No es necesario decir que hay pocos problemas como éste en la vida real. La no linealidad es la norma, donde cambiar un componente puede tener efectos en cadena en todo el sistema, y donde cambios múltiples que, individualmente, son perjudiciales, en combinación pueden conducir hacia mejoras importantes sobre la aptitud. La no linealidad produce una explosión combinatoria: el espacio de cadenas binarias de 1000 dígitos puede examinarse exhaustivamente evaluando sólo 2000 posibilidades si el problema es lineal, mientras que si no es lineal, una búsqueda exhaustiva requiere evaluar 21000 posibilidades, un número que, escrito, ocuparía más de 300 dígitos.

Afortunadamente, el paralelismo implícito de los AG's les permite superar incluso este enorme número de posibilidades, y encontrar con éxito resultados óptimos o muy buenos en un corto periodo de tiempo, tras muestrear directamente sólo regiones pequeñas del vasto paisaje adaptativo (Forrest 1993).

Otra ventaja notable de los algoritmos genéticos es que se desenvuelven bien en problemas con un paisaje adaptativo complejo, aquéllos en los que la función de aptitud es discontinua, ruidosa, cambia con el tiempo, o tiene muchos óptimos locales. La mayoría de los problemas prácticos tienen un espacio de soluciones enorme, imposible de explorar exhaustivamente; el reto se convierte entonces en cómo evitar los óptimos locales, soluciones que son mejores que todas las que son similares a ella, pero que no son mejores que otras soluciones distintas situadas en algún otro lugar del espacio de soluciones. Muchos algoritmos de búsqueda pueden quedar atrapados en los óptimos locales: si llegan a lo alto de una colina del paisaje adaptativo, descubrirán que no existen soluciones mejores en las cercanías y concluirán que han alcanzado la mejor de todas, aunque existan picos más altos en algún otro lugar del mapa.

Los algoritmos evolutivos, por otro lado, han demostrado su efectividad al escapar de los óptimos locales y descubrir el óptimo global incluso en paisajes adaptativos muy escabrosos y complejos. Debe decirse que, en la realidad, a menudo no hay manera de decir si una

cierta solución a un problema es el óptimo global o sólo un óptimo local muy alto. Sin embargo, aunque un AG no devuelva siempre una solución perfecta y demostrable a un problema, casi siempre puede devolver al menos una muy buena solución. Los cuatro componentes principales de los AG's, paralelismo, selección, mutación y cruzamiento, trabajan juntos para conseguir esto.

Sin embargo, el cruzamiento es el elemento clave que distingue a los algoritmos genéticos de los otros métodos como la búsqueda tabú, los trepacolinas y el recocido simulado. Sin el cruzamiento, cada solución individual va por su cuenta, explorando el espacio de búsqueda en su vecindario sin referencia de lo que el resto de individuos puedan haber encontrado. Sin embargo, con el cruzamiento en juego, hay una transferencia de información entre los candidatos prósperos, los individuos pueden beneficiarse de lo que otros han aprendido, y los esquemas pueden mezclarse y combinarse, con el potencial de producir una descendencia que tenga las virtudes de sus dos padres y ninguna de sus debilidades. El problema de encontrar el óptimo global en un espacio con muchos óptimos locales también se conoce como el dilema de la exploración versus explotación, "un problema clásico de todos los sistemas que pueden adaptarse y aprender" (Holland, 1992). Una vez que un algoritmo (o un diseñador humano) ha encontrado una estrategia para resolver problemas que parece funcionar satisfactoriamente, ¿debería centrarse en hacer el mejor uso de esa estrategia, o buscar otras? Abandonar una estrategia de probada solvencia para buscar otras nuevas casi garantiza que supondrá una pérdida y degradación del rendimiento, al menos a corto plazo. Pero si uno se queda con una estrategia particular excluyendo a todas las demás, corre el riesgo de no descubrir estrategias mejores que existen pero no se han encontrado. De nuevo, los algoritmos genéticos han demostrado ser muy buenos en dar con este equilibrio y descubrir buenas soluciones en un tiempo y esfuerzo computacional razonables.

Otra gran ventaja de los algoritmos genéticos es su habilidad para manipular muchos parámetros simultáneamente (Forrest, 1993). Muchos problemas de la vida real no pueden definirse en términos de un único valor que hay que minimizar o maximizar, sino que deben expresarse en términos de múltiples objetivos, a menudo involucrando contrapartidas: uno sólo puede mejorar a expensas de otro. Los AG's son muy buenos resolviendo estos problemas: en particular, su uso del paralelismo les permite producir múltiples soluciones, igualmente buenas, al mismo problema donde posiblemente una solución candidata optimiza un parámetro y otra candidata optimiza uno distinto (Haupt y Haupt, 1998) , y luego un supervisor humano puede seleccionar una de esas candidatas para su utilización. Si una solución particular a un problema con múltiples objetivos optimiza un parámetro hasta el punto en el que ese parámetro no puede mejorarse más sin causar una correspondiente pérdida de calidad en algún otro parámetro, esa solución se llama óptimo paretiano o no dominado. (Coello, 2000)

Finalmente, una de las cualidades de los algoritmos genéticos que, a primera vista, puede parecer un desastre, resulta ser una de sus ventajas: a saber, los AG's no saben nada de los problemas que deben resolver. En lugar de utilizar información específica conocida a priori para guiar cada paso y realizar cambios con un ojo puesto en el mejoramiento, como hacen los diseñadores humanos, son "relojeros ciegos" (Dawkins, 1996); realizan cambios aleatorios en sus soluciones candidatas y luego utilizan la función de aptitud para determinar si esos cambios producen una mejora.

La virtud de esta técnica es que permite a los algoritmos genéticos comenzar con una mente abierta, por así decirlo. Como sus decisiones están basadas en la aleatoriedad, todos los caminos de búsqueda posibles están abiertos teóricamente a un AG. En contraste, cualquier estrategia de resolución de problemas que dependa de un conocimiento previo, debe inevitablemente comenzar descartando muchos caminos a priori, perdiendo así cualquier solución novedosa que pueda existir (Koza et al. ,1999). De manera similar, cualquier

técnica que dependa de conocimiento previo fracasará cuando no esté disponible tal conocimiento, pero, de nuevo, los AG's no se ven afectados negativamente por la ignorancia (Goldberg, 1989). Mediante sus componentes de paralelismo, cruzamiento y mutación, pueden viajar extensamente por el paisaje adaptativo, explorando regiones que algoritmos producidos con inteligencia podrían no haber tenido en cuenta, y revelando potencialmente soluciones de asombrosa e inesperada creatividad que podrían no haberseles ocurrido nunca a los diseñadores humanos.

3.11 Limitaciones de los Algoritmos Genéticos

Aunque los algoritmos genéticos han demostrado su eficacia y capacidad como estrategia de resolución de problemas, no son la panacea. Los AG's tienen ciertas limitaciones; sin embargo, se demostrará que todas ellas pueden superarse y que ninguna de ellas afecta a la validez de la evolución biológica.

La primera y más importante consideración al crear un algoritmo genético es definir una representación del problema. El lenguaje utilizado para especificar soluciones candidatas debe ser robusto; es decir, debe ser capaz de tolerar cambios aleatorios que no produzcan constantemente errores fatales o resultados sin sentido.

Hay dos maneras principales para conseguir esto. La primera, utilizada por la mayoría de los algoritmos genéticos, es definir a los individuos como listas de números, binarios, enteros o reales, donde cada número representa algún aspecto de la solución candidata. Si los individuos son cadenas binarias, un 0 o 1 podría significar la ausencia o presencia de una cierta característica. Si son listas de números, estos números podrían representar muchas cosas distintas: el orden de las ciudades visitadas en un recorrido dado, la situación espacial de componentes electrónicos, los valores con los que se alimenta a un controlador, los ángulos de torsión de los enlaces péptidos de una proteína, los identificadores de barras en un ensamble de combustible de un reactor nuclear, etcétera. Así, la mutación implica cambiar estos números, cambiar bits o sumar o restar valores aleatorios. En este caso, el propio código del programa no cambia; el código es lo que dirige la simulación y hace un seguimiento de los individuos, evaluando sus aptitudes y quizá asegurando que sólo se producen valores realistas y posibles para el problema dado.

El problema de representar a las soluciones candidatas de manera robusta no surge en la naturaleza, porque el método de representación utilizado por la evolución, a saber, el código genético, es inherentemente robusto: con muy pocas excepciones. Por lo tanto, virtualmente, cualquier cambio en los genes de un individuo siempre producirá un resultado inteligible, y por tanto las mutaciones en la evolución tienen mayor probabilidad de producir una mejora.

El problema de cómo escribir la función de aptitud (o función objetivo) debe considerarse cuidadosamente para que se pueda alcanzar una mayor aptitud y verdaderamente signifique una solución mejor para el problema dado. Si se elige mal una función de aptitud o se define de manera inexacta, puede que el algoritmo genético sea incapaz de encontrar una solución al problema, o puede acabar resolviendo el problema equivocado. Sin embargo, esto no es un problema en la naturaleza. En el laboratorio de la evolución biológica, sólo hay una función de aptitud que es igual para todos los seres vivos, la carrera por sobrevivir y reproducirse, sin importar qué adaptaciones hagan esto posible. Los organismos que se reproducen con más abundancia que sus competidores están más adaptados; los que fracasan en reproducirse no están adaptados.

Además de elegir bien la función de aptitud, también deben elegirse cuidadosamente los otros parámetros de un AG, el tamaño de la población, el ritmo de mutación y cruzamiento, el tipo y fuerza de la selección. Si el tamaño de la población es demasiado pequeño, puede

que el algoritmo genético no explore suficientemente el espacio de soluciones para encontrar buenas soluciones consistentemente. Si el ritmo de cambio genético es demasiado alto o el sistema de selección se escoge inadecuadamente, puede alterarse el desarrollo de esquemas beneficiosos y la población puede entrar en catástrofe de errores, al cambiar demasiado rápido para que la selección llegue a producir convergencia.

Los seres vivos también se enfrentan a dificultades similares, y la evolución se ha encargado de ellas. Es cierto que si el tamaño de una población cae hacia un valor muy bajo, los ritmos de mutación son muy altos o la presión selectiva es demasiado fuerte (una situación así podría ser resultado de un cambio ambiental drástico), entonces la especie puede extinguirse. La mayoría de los seres vivos han evolucionado una elaborada maquinaria celular que comprueba y corrige errores durante el proceso de replicación del ADN, manteniendo su ritmo de mutación a unos niveles aceptablemente bajos; a la inversa, en tiempos de fuerte presión ambiental, algunas especies de bacterias entran en un estado de hipermutación en el que el ritmo de errores en la replicación del ADN aumenta bruscamente, aumentando la probabilidad de que se produzca una mutación compensatoria. Por supuesto, no pueden eludirse todas las catástrofes, pero la enorme diversidad y las adaptaciones altamente complejas de los seres vivos actuales muestran que, en general, la evolución es una estrategia exitosa. Igualmente, las aplicaciones diversas de los AGs y los impresionantes resultados demuestran que son un campo de estudio poderoso.

Un problema con el que los algoritmos genéticos tienen dificultades son los problemas con las funciones de aptitud "engañosas" (Mitchell, 1996), en las que la situación de los puntos mejorados ofrece información engañosa sobre dónde se encuentra probablemente el óptimo global. Por ejemplo: imagine un problema en el que el espacio de búsqueda esté compuesto por todas las cadenas binarias de ocho caracteres, y en el que la aptitud de cada individuo sea directamente proporcional al número de unos en él, es decir, 00000001 sería menos apto que 00000011, que sería menos apto que 00000111, etcétera, con dos excepciones: la cadena 11111111 resulta tener una aptitud muy baja, y la cadena 00000000 resulta tener una aptitud muy alta. En este problema, un AG (al igual que la mayoría de los algoritmos) no tendría más probabilidad de encontrar un óptimo global que una búsqueda aleatoria.

La solución a este problema es la misma para los algoritmos genéticos y la evolución biológica: la evolución no es un proceso que deba encontrar siempre el óptimo global. Puede funcionar casi igual de bien alcanzando la cima de un óptimo local alto y, para la mayoría de las situaciones, eso será suficiente, incluso aunque el óptimo global no pueda alcanzarse fácilmente desde ese punto. La evolución es como un "satisfactor", un algoritmo que entrega una solución "suficientemente buena", aunque no necesariamente la mejor solución posible, dada una cantidad razonable de tiempo y esfuerzo invertidos en la búsqueda.

Un problema muy conocido que puede surgir con un AG se conoce como convergencia prematura. Si un individuo que es más apto que la mayoría de sus competidores emerge muy pronto en el curso de la ejecución, se puede reproducir tan abundantemente que merme la diversidad de la población demasiado pronto, provocando que el algoritmo converja hacia el óptimo local que representa ese individuo, en lugar de rastrear el paisaje adaptativo lo bastante a fondo para encontrar el óptimo global (Forrest, 1993 y Mitchell, 1996). Esto es un problema especialmente común en las poblaciones pequeñas, donde incluso una variación aleatoria en el ritmo de reproducción puede provocar que un individuo se haga dominante sobre los otros.

La convergencia prematura ocurre en la naturaleza (los biólogos la llaman deriva genética). Esto no debe sorprender; como ya se dijo arriba, la evolución, como estrategia de resolución de problemas, no está obligada a encontrar la mejor solución, sólo una que sea lo bastante buena. Sin embargo, en la naturaleza, la convergencia prematura es menos común, ya que la mayoría de las mutaciones beneficiosas en los seres vivos sólo producen mejoras en la

aptitud pequeñas e incrementales; son raras las mutaciones que producen una ganancia de aptitud tan grande que otorgue a sus poseedores una drástica ventaja reproductiva.

Finalmente, varios investigadores (Holland, 1992, Forrest, 1993, Haupt y Haupt, 1998) aconsejan no utilizar algoritmos genéticos en problemas resolubles de manera analítica. No es que los algoritmos genéticos no puedan encontrar soluciones buenas para estos problemas; simplemente es que los métodos analíticos tradicionales consumen mucho menos tiempo y capacidad computacional que los AG's y, a diferencia de los ellos a menudo está demostrado matemáticamente que ofrecen la única solución exacta. Por supuesto, como no existe una solución matemática perfecta para ningún problema de adaptación biológica, este problema no aparece en la naturaleza.



Aplicación de los Algoritmos Genéticos

La aplicación de la técnica de los algoritmos genéticos para la solución del diseño radial de combustible se describe en este capítulo. Además, el capítulo presenta el simulador neutrónico utilizado para obtener los parámetros neutrónicos utilizados en el proceso de optimización.

En este trabajo se desarrolló un sistema computacional que trabaja en el sistema operativo Linux para el diseño y optimización radial de celdas de combustible para BWR basado en AG's y reglas heurísticas.

A diferencia de desarrollos previos (Martín del Campo, 2004), en este trabajo se utilizó CASMO-4 como simulador neutrónico.

4.1 Simulador Neutrónico CASMO-4

CASMO-4 es un código usado para análisis de criticidad, diseño de combustible y generación de bancos de datos nucleares para aplicaciones de modelado del núcleo de reactores de potencia BWR y PWR. Resuelve la Ecuación de Transporte de Neutrones en multigrupos en dos dimensiones utilizando un modelo completamente heterogéneo. Los datos nucleares están reunidos en una biblioteca que contiene secciones eficaces microscópicas en 70 grupos de energía, los datos de la biblioteca están basados principalmente en la ENDF/B-IV. (Studsvik, 2004).

Con CASMO-4 se pueden modelar, tanto configuraciones geométricas multi-ensamble, como configuraciones de piscina de combustible gastado para análisis de criticidad. Por ejemplo, los arreglos frescos y gastados pueden combinarse en estas configuraciones geométricas extendidas para analizar quemado de combustible (Studsvik, 2004). Además del análisis de arreglos de combustible, CASMO-4 es usado también para generar el banco de datos de las constantes nucleares requeridas por los códigos de análisis desarrollados por Studsvik Scandpower. Estos incluyen:

- Análisis de núcleo en estado estable.
- Análisis de transitorios.
- Modelos de simulador de entrenamiento del núcleo.
- Monitoreo del núcleo.
- Seguimiento automatizado del núcleo.
- Cálculos de fuente y de calor de decaimiento.

4.2 Representación de la solución

La aplicación se realizó con base en un ensamble utilizado en los reactores de la CNLV (Central Nucleoeléctrica de Laguna Verde), se trata de un arreglo de 10x10 barras de combustible. Se pueden utilizar cualquier número de composiciones diferentes, con enriquecimiento en U^{235} y concentración de gadolinia variables.

El arreglo tiene dos tubos de agua en posiciones fijas. Todas las dimensiones de barras combustibles y estructuras se consideran fijas.

La representación de la celda debe estar directamente relacionada con la forma en que ésta es modelada en el simulador que vaya a ser utilizado para evaluar neutrónicamente el diseño.

En la simulación de la celda con CASMO-4, las barras de combustible, las regiones de agua, el canal envolvente y la barra de control cruciforme se representan explícitamente en el espacio de dos-dimensiones.

La celda es simétrica con respecto a la diagonal indicada en la Figura 4.1, y en CASMO-4 esta celda puede ser representada usando condición de reflexión en dicha diagonal y ser representada por 55 posiciones como se esquematiza en la Figura 4.2.

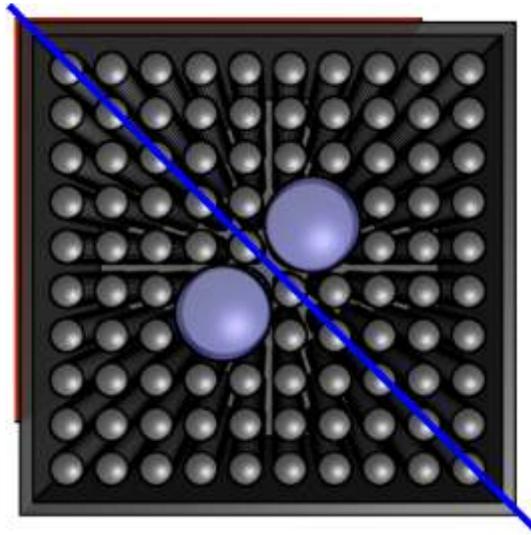


Figura 4.1. Sección Radial de una Celda de Combustible 10x10

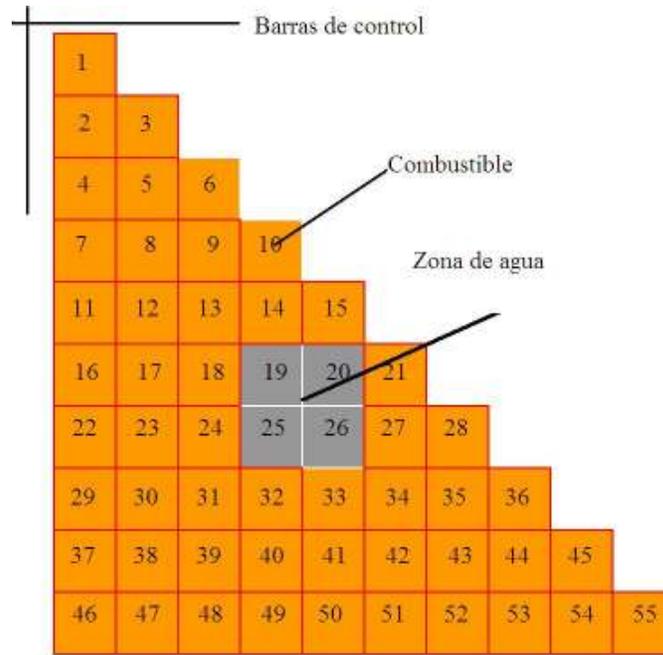


Figura 4.2. Representación Esquemática de la Celda de Combustible con Simetría Diagonal

4.2.1 Composiciones de Combustible en la Celda

En esta aplicación la celda a diseñar ha sido utilizada en la parte inferior de uno de los ensambles frescos del ciclo 10 de la Unidad 1 de la CNLV. No presenta barras vacías (barras sin combustible) ni huecos de agua (posiciones en las que no hay presencia de barra). Tomando en cuenta aspectos relacionados con la manufactura de los ensambles

combustibles, únicamente se consideraron 10 diferentes composiciones de combustible, las cuales ya han sido utilizadas en los ensambles combustibles de la CNLV.

En la Tabla 4.1 se muestran las composiciones de estos combustibles, de los cuales cuatro contienen gadolinia (Martín del Campo, 2007).

Composición	1	2	3	4	5	6	7	8	9	10
U ²³⁵ %w	2.0	2.8	3.6	4.4	3.95	4.9	3.95	4.4	4.4	4.4
Gadolinia %w	0	0	0	0	0	0	5	5	4	2

%w= porcentaje en peso

Tabla 4.1. Enriquecimientos y Concentraciones de Gadolinia en las Composiciones

Para evaluar neutrónicamente diferentes distribuciones radiales de enriquecimiento y gadolinia en la celda de combustible, los datos requeridos por CASMO-4, son entre otros, el enriquecimiento de uranio (en % en masa de U²³⁵ del uranio) y el contenido de gadolinia (en % en masa de gadolinia) en la mezcla de dióxido de uranio y gadolinia de las diferentes barras de combustible, estos datos se van a hacer variar y para ello se definen las composiciones de combustible caracterizadas por los porcentajes de enriquecimiento y de gadolinia en el combustible. CASMO-4 requiere dentro de sus datos, un arreglo bidimensional indicando la composición del combustible localizado en cada una de las posiciones (de barras) dentro del ensamble.

Para este caso se tienen 10 diferentes composiciones de combustible distribuidas en 51 posiciones (restando las 4 posiciones de agua, que son fijas) en el ensamble. Entonces el número de soluciones viables es 10^{51} . Con el objeto de utilizar la terminología empleada en la técnica de AG, en lugar de hablar de una distribución de enriquecimientos se hablará de un individuo en el desarrollo de los Algoritmos Genéticos en este trabajo.

4.2.2 Reglas Heurísticas

Es conveniente reducir el número de combinaciones posibles a ser investigadas sin reducir la calidad de la optimización y para ello se aplicaron algunas reglas heurísticas de acomodo:

Regla 1: Los combustibles que contienen gadolinia no pueden ser colocados en posiciones periféricas.

Regla 2: El combustible de menor enriquecimiento se fija y se utiliza únicamente en las esquinas de la celda en las posiciones 1, 46 y 55.

Regla 3: Las posiciones ocupadas por tubos de agua son fijas.

Tomando en cuenta las tres reglas heurísticas mencionadas y que cuatro de las composiciones tienen gadolinia; se tienen 16 posiciones que pueden llenarse con 5 diferentes composiciones de combustible y 32 posiciones que pueden llenarse con 9 diferentes composiciones de combustible. El número total de combinaciones resultante se puede calcular como:

$$5^{16} \times 9^{32} = 5 \times 10^{41}$$

Este número de combinaciones representa el número total de soluciones candidatas que tendrían que ser investigadas si se realizase una búsqueda exhaustiva. Este número es muy grande por lo que se aplicó una estrategia para reducir el espacio de búsqueda sin disminuir la calidad de los resultados. Consistió en aplicar dos reglas más:

Regla 4: Los individuos creados tienen enriquecimiento promedio entre E_{min} y E_{max}

Regla 5: Los individuos creados tienen gadolinia promedio entre G_{min} y G_{max}

Estas restricciones eliminan la posibilidad de mandar evaluar con CASMO-4 a individuos que no interesan desde el punto de vista de enriquecimiento y gadolinia y eso a su vez también elimina la necesidad de realizar cálculos de quemado con CASMO-4 lo que implicaría un uso muy intensivo de tiempo de cómputo.

4.3. Modelo Matemático de la Función Objetivo

De todos esos individuos algunos de ellos cumplirán con las restricciones de reactividad y de pico de potencia, los cuales forman el conjunto de individuos que podrían ser una solución factible. Para determinar si un individuo es candidato a ser el mejor se tiene que realizar la simulación con CASMO-4 y obtener los parámetros de k-infinita y PPF. La función objetivo fue formulada para buscar la solución x con la distribución de enriquecimiento y gadolinia que satisfaga mejor los siguientes cuatro objetivos:

- El menor enriquecimiento promedio $E(x)$
- El contenido promedio de gadolinia $G(x)$ igual al deseado $G_{objetivo}$
- El $PPF_0(x)$ menor que el límite máximo PPF_{max} a 0 MWd/t
- La $k_{inf}(x)$ igual a deseada $k_{inf_objetivo}$ a 0 MWd/t

La función objetivo a minimizar quedó representada matemáticamente en la Ecuación 4.1; y en la Tabla 4.2 se presenta la definición de cada término.

$$F(x) = w_E \cdot E(x) + w_G \cdot |G(x) - G_{objetivo}| + w_P \cdot (PPF_0(x) - PPF_{max}) + w_k \cdot (k_{inf}(x) - k_{inf_objetivo})^2 \quad (4.1)$$

x	Vector de composiciones de combustible asociadas a las posiciones en la celda
$F(x)$	Función objetivo (con evaluación a 0 MWd/t)
$E(x)$	Enriquecimiento promedio de la celda x , a 0 MWd/t
$G(x)$	Concentración promedio de gadolinia en la celda x , a 0 MWd/t
$G_{objetivo}$	Concentración promedio de gadolinia <i>objetivo</i> , a 0MWd/t
$PPF_0(x)$	Factor del Pico de Potencia Radial de la celda x , a 0 MWd/t
PPF_{max}	Límite máximo del PPF a 0 MWd/t
$k_{inf}(x)$	k_{inf} a 0 MWd/t, para la solución x
$k_{inf_objetivo}$	k_{inf} <i>objetivo</i> , a 0 MWd/t para la solución x
w_E	Factor de peso para el término del enriquecimiento
w_G	Factor de peso para el término de la gadolinia
w_P	Factor de peso para el término del PPF
w_k	Factor de peso para el término de k-infinita

Tabla 4.2. Definición de Términos en el Modelo Matemático de la Función Objetivo

Los factores de peso w_E , w_G , w_P y w_k ponderan la importancia de los diferentes términos y son obtenidos a partir del propio uso de la función objetivo (ecuación 4.1) mediante la observación de la calidad de los resultados.

El primer objetivo consiste en buscar el menor valor de $E(\mathbf{x})$ posible. El valor de $E(x)$ se calcula a partir de la ecuación:

$$E(x) = \sum_{j=1}^{92} \frac{E(j)}{92} \dots\dots\dots(4.2)$$

Debe notarse que esta ecuación representa el enriquecimiento promedio $E(\mathbf{x})$ de la celda, considerando 92 posiciones de barras combustibles dentro del arreglo 10x10, estando 8 posiciones ocupadas por las dos barras de agua.

Para satisfacer el segundo objetivo se minimiza:

$$|G(\mathbf{x}) - G_{\text{objetivo}}|$$

Donde:

$$G(x) = \sum_{j=1}^{92} \frac{G(j)}{92} \dots\dots\dots(4.3)$$

Para satisfacer el tercer objetivo se busca:

$$PPF_0(x) - PPF_{max} < 0 \dots\dots\dots(4.4)$$

Para buscar el cuarto objetivo se minimiza la diferencia entre la k-infinita de la solución x , ($k_{inf}(x)$) y el valor de k-infinita objetivo ($k_{inf_objetivo_i}$) a 0 MWd/t. Cabe señalar que los valores $PPF_0(x)$, y $k_{inf_i}(x)$ se obtienen ejecutando el código CASMO-4 para la celda x en 0 MWd/t.

4.4. Aplicación del Algoritmo Genético

Como se muestra en la Figura 4.3, para iniciar se debe realizar la lectura de datos relacionados con los AG's: tamaño de la población, número total de generaciones, probabilidad de cruza, probabilidad de mutación. Esto se hace a través de la declaración de variables dentro del programa. Además se establecen los valores objetivo y de referencia, estos valores se obtienen de los parámetros neutrónicos arrojados por la ejecución de CASMO-4 para la celda de referencia. En la aplicación reportada se utilizó CASMO-4, sin embargo el programa de optimización está preparado para utilizar HELIOS si se considerara necesario.



Figura 4.3. Diagrama de flujo de la aplicación del Algoritmo Genético

Los individuos de la primera población se generarán aleatoriamente llenando un arreglo en el cual se acomodan las 10 composiciones que se tienen (Tabla 4.1) en las 55 posiciones representadas en la solución factible (Figura 4.2). El algoritmo de generación de individuos está diseñado de tal modo que siempre se cumple con la reglas heurísticas 1, 2 y 3 antes mencionadas. A cada individuo, se le asigna un identificador (descrito más adelante) y se le calcula el enriquecimiento promedio (Ecuación 4.2) y la concentración promedio de gadolína (ecuación 4.3); el individuo que no cumpla con las reglas heurísticas 4 y 5 es descartado. Este proceso se repite hasta completar el número de individuos que representa la población en la primera generación. Cabe mencionar que se ha tenido el cuidado de que en la población no existan individuos idénticos.

A continuación se muestra un ejemplo de la representación de una solución en forma de cromosoma. Se trata de un vector x de la forma:

$$x = [a_1, a_2, \dots, a_{54}, a_{55}]$$

donde a_i ($i=1,55$) toman los valores $\{1,2,\dots,10\}$ de las composiciones descritas en la Tabla 4.1, respetando las reglas heurísticas de la Sección 4.2.2.

Recordando que esta aplicación está basada en el comportamiento de los seres vivos y su evolución, tenemos que cada individuo de la población tiene que hacer frente al problema de la supervivencia. Para el caso de esta aplicación su superioridad la demuestran los individuos al ser evaluados con la función objetivo, ecuación 4.1, y obtener su calificación, de acuerdo a la cual serán acomodados. Esto influirá en la probabilidad de trascendencia que tendrán las características de cada individuo en las siguientes generaciones.

Para la selección de padres a cruzarse, se ha escogido la selección proporcional tipo ruleta en la cual se suman las calificaciones y se determina la fracción de ese total que corresponde a cada diseño.

La probabilidad de cruzamiento, dentro de esta aplicación, determina la posibilidad de que dos individuos seleccionados como padres tengan descendencia. Para la selección de individuos que pasan de una generación a otra se ha implementado la competencia de individuos padres, de individuos hijos del cruzamiento y de individuos creados por mutación. Esto cumple con un modelo global de selección en el cual todos los individuos de la población pueden ser seleccionados, con esto se busca que las características que se tienen no se pierdan al ser cruzados, o bien que si se tiene una población de características malas se pueda mejorar.

El operador de cruzamiento crea nuevos individuos mediante la combinación de partes de dos individuos llamados padres utilizando un punto de cruce (que es la posición desde la cual se hará el intercambio de información), el punto de cruce se selecciona de manera aleatoria, excluyendo los puntos 1, 2, 54, 55, de acuerdo a la numeración de la Figura 4.2, debido a que si se toma desde ahí, el individuo obtenido sería idéntico al padre. A continuación se muestra un ejemplo de la operación de cruzamiento cuando el punto de cruce es la posición 4.

Padres:	$x1=[a_1, a_2, a_3, a_4, a_5, a_6\dots\dots, a_{52}, a_{53}, a_{54}, a_{55}]$
	$x2=[A_1, A_2, A_3, A_4, A_5, A_6\dots\dots, A_{52}, A_{53}, A_{54}, A_{55}]$
Hijos	$xh1=[A_1, A_2, A_3, A_4, a_5, a_6\dots\dots, a_{52}, a_{53}, a_{54}, a_{55}]$
	$xh2=[a_1, a_2, a_3, a_4, A_5, A_6\dots\dots, A_{52}, A_{53}, A_{54}, A_{55}]$

Un individuo de una nueva generación reemplaza a uno de la generación precedente cuando su calificación es mejor que la del menos apto de la generación precedente.

Si la calificación del individuo es igual a la de alguno de la generación precedente, el individuo es descartado. El proceso se detiene cuando se satisface el número de generaciones requerido como dato, el cual es determinado por el analista que utiliza el sistema basándose en la experiencia obtenida con el uso del mismo.

Ya que en un AG se trata de explorar un enorme espacio de posibilidades. Al encontrar una zona con calificaciones altas, ésta se explora más a fondo. Pero hay que evitar que el algoritmo se estanque en una determinada zona, produciendo multitud de individuos muy parecidos. De igual forma se ha de evitar lo contrario, que el algoritmo distribuya tan uniformemente el espacio de búsqueda que casi se dejen de explorar las mejores zonas, esto se logra al implementar la operación de mutación, la cual tiene como función hacer cambios pequeños en los individuos para poder encontrar una pequeña variante que tal vez

mejore a la población y que este cambio no sea tan radical como lo hace la operación de cruzamiento.

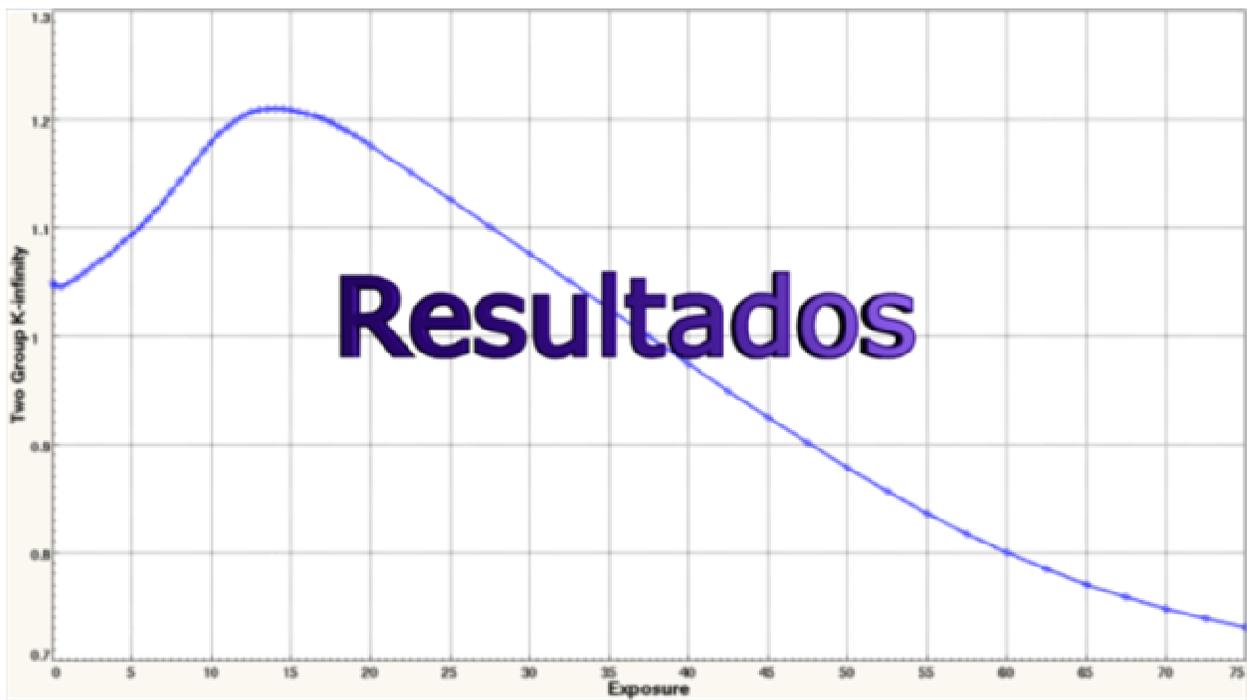
Para esta aplicación, la probabilidad de mutación define la posibilidad de que cada hijo creado pueda presentar una mutación. La posición de mutación se elige de manera aleatoria, excluyendo los puntos 1, 46 y 55, debido a que las reglas heurísticas determinan que el valor de esas celdas es fijo.

Las zonas de agua también son excluidas. Posteriormente se selecciona aleatoriamente de la tabla de composiciones de combustible (Tabla 4.1) y se acomoda en el punto de mutación. Para asegurar que la mutación sea efectiva, se verifica que la composición que se selecciona sea diferente de la que ya se tenía en ese punto y que cumpla con las reglas heurísticas. Este operador permite introducir nuevo material en la composición del ensamble y de esta manera variar el enriquecimiento promedio del mismo. A continuación se muestra un ejemplo de la operación de mutación sobre la posición 5, en este caso, el individuo contiene la composición 3 y después de la mutación esa posición contiene la composición 4, sin ningún otro cambio adicional.

Individuo:	$x=[a_1, a_2, a_3, a_4, \mathbf{a_5}, a_6, \dots, a_{52}, a_{53}, a_{54}, a_{55}]$ con $a_5= 3$
Individuo mutado:	$xm=[a_1, a_2, a_3, a_4, \mathbf{a_5}, a_6, \dots, a_{52}, a_{53}, a_{54}, a_{55}]$ con $a_5= 4$

El programa de optimización asigna un número único a cada individuo creado (aunque haya sido descartado por no cumplir con las reglas heurísticas 4 y 5 o no haya "sobrevivido" a la competencia entre individuos en cada generación) para que sirva de identificador. Este número nos permite una mejor organización y control de los individuos además de que amplía las posibilidades de usos de cada individuo.

La utilidad del identificador puede notarse dentro de otras características del programa ya que éste incluye en sus archivos de salida: mapas de distribución de composiciones, los archivos de entrada para CASMO-4 y todos los parámetros neutrónicos de todos los individuos. Los datos de los archivos de salida que incluyen parámetros neutrónicos están representados con valores separados por comas, esto automatiza su visualización y por lo tanto su manejo en los programas de hoja de cálculo (Calc, Excel). Por último, el programa asigna automáticamente los nombres de los archivos de salida creados con el fin de facilitar la organización de los resultados. El formato de los nombres que asigna el programa en sus ejecuciones contiene la fecha y hora de creación, además del tamaño de la población y el número de generaciones.



En esta sección se muestran los resultados del ejemplo de aplicación para una celda de combustible similar a una utilizada en la parte inferior de un lote de ensambles de combustible actualmente introducido en la CNLV

La función objetivo a minimizar se mostró en la ecuación (4.1). Los factores de peso w_E , w_G , w_P y w_k toman distintos valores de acuerdo a las condiciones que se muestran en la Tabla 5.1, las cuales consideran las preferencias de diseño. Por ejemplo, el enriquecimiento es un parámetro que se busca minimizar por lo que se penaliza más fuertemente a los diseños con enriquecimientos promedio $E(x)$ superiores a E_{ref} que los diseños de enriquecimiento menor. En el caso de la gadolinia se busca un valor deseado (*objetivo*) pero se penaliza más a los diseños con gadolinia promedio $G(x)$ mayor que $G_{objetivo}$ que cuando es menor. El parámetro PPF (Power Peaking Factor) se desea minimizar por lo tanto se penaliza con mayor peso a los diseños con $PPF(x)$ mayor a PPF_{max} que a los diseños con $PPF(x)$ inferior, etc.

Si	Entonces
$E(x) < E_{ref}$	$w_E = 1$
$E(x) > E_{ref}$	$w_E = 3$
$G(x) < G_{objetivo}$	$w_G = 15$
$G(x) > G_{objetivo}$	$w_G = 20$
$PPF(x) < PPF_{max}$	$w_P = 100$
$PPF(x) > PPF_{max}$	$w_P = 300$
$k_{inf}(x) < k_{inf_objetivo}$	$w_k = 20000$
$k_{inf}(x) > k_{inf_objetivo}$	$w_k = 10000$

Tabla 5.1. Valores de los Pesos que Intervienen en la Función Objetivo

La Tabla 5.2 muestra los parámetros del algoritmo genético que se usaron para obtener los resultados mostrados en este trabajo, estos parámetros fueron determinados con base a la experiencia proporcionada por el uso del algoritmo.

Probabilidad de cruza (%)	50
Probabilidad de mutación (%)	20
Número de generaciones	200
Individuos en la población	40

Tabla 5.2 Parámetros del Algoritmo Genético en la Ejecución

A continuación se describen los dos casos de aplicación que se analizaron:

CASO 1

En la Tabla 5.2 se muestran los valores *objetivo* y valores límite en el primer caso de aplicación. El valor de E_{ref} se considera igual al de una celda de referencia (identificada por 1G37) utilizada en la parte inferior de un lote de combustible de la CNLV, por lo que los cálculos neutrónicos se realizaron en condiciones de plena potencia y 0% de vacíos.

Variable	E_{max}	E_{min}	E_{ref}	$G_{objetivo}$	G_{max}	G_{min}	$k_{inf_objetivo}$	PPF_{max}
Valor	4.15%	3.87%	4.1%	0.8152%	0.82%	0.80%	1.04370	1.424

Tabla 5.3 Valores Objetivo y Valores Límite para los Parámetros (Caso 1)

En la Figura 5.1 se muestra la evolución del enriquecimiento promedio de los individuos de cada generación. El valor se mantuvo dentro de los rangos que se marcan en la Tabla 5.2 y al final del proceso de optimización se obtuvo un valor inferior al de la celda de referencia lo cual era lo buscado. Otra de las metas que se pudo cumplir es el de que la población tenga un promedio de gadolinia establecido ($G_{objetivo}$).

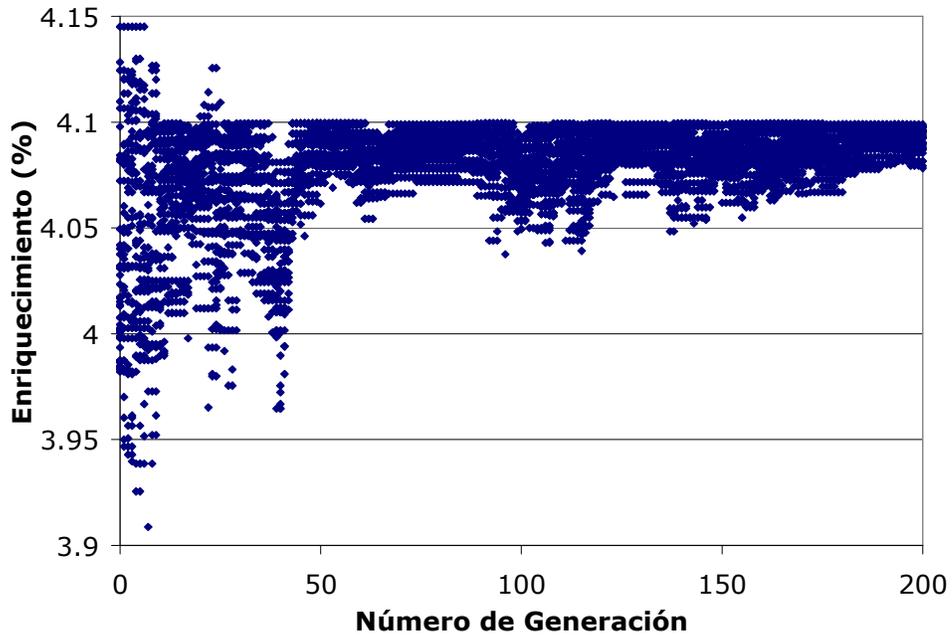


Figura 5.1. Evolución del Enriquecimiento para los Individuos dentro de la Generación (Caso 1)

El parámetro que se muestra en la Figura 5.2 es el de k-infinita. Este parámetro evolucionó hacia el valor buscado ($k_{inf_objetivo}$)

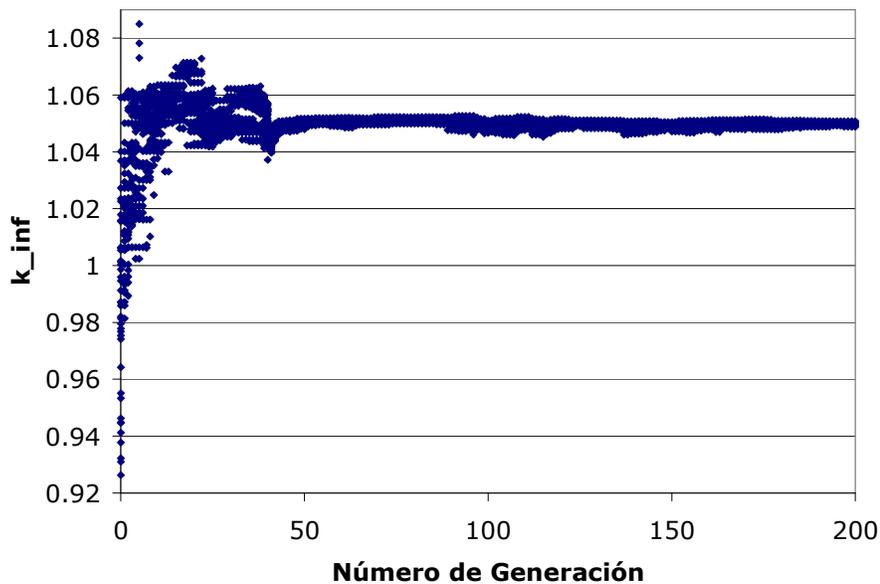


Figura 5.2. Evolución de k_inf para los Individuos dentro de la Generación (Caso 1)

En la Figura 5.3, se grafica el valor del PPF que fue definido en la Tabla 5.2 y que también evolucionó disminuyendo hasta llegar a un valor inferior al límite de PPFmax.

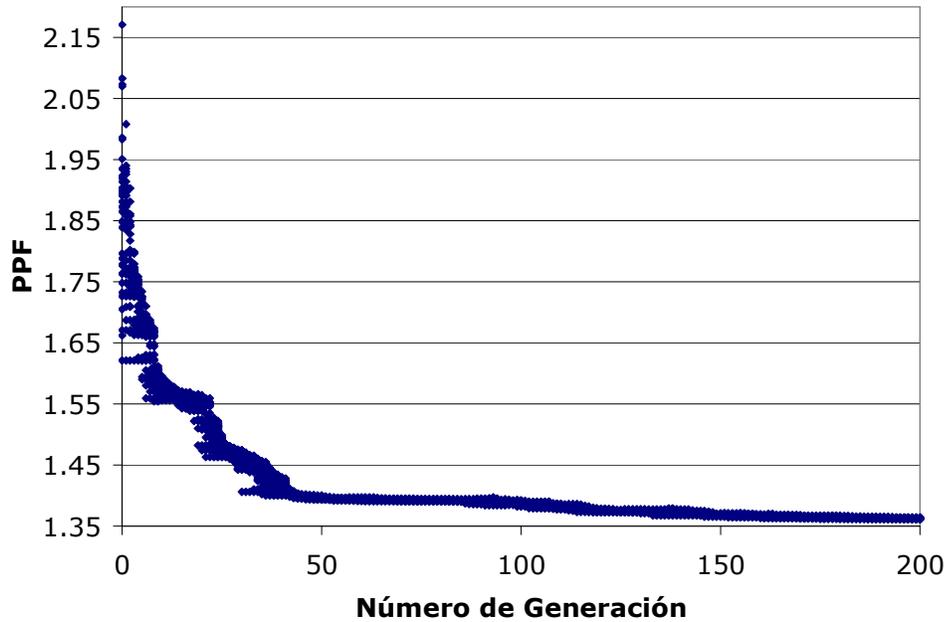


Figura 5.3. Evolución del PPF de los Individuos dentro de la Generación (Caso 1)

Pero uno de los principales aspectos que se esperaba alcanzar era el de minimizar el valor de la calificación que proporcionaba la función objetivo $F(x)$, ecuación 4.1, y que se puede apreciar en la siguiente gráfica, Figura 5.4, en donde se observa que en general la calificación se va disminuyendo conforme se avanza en el número de generación.

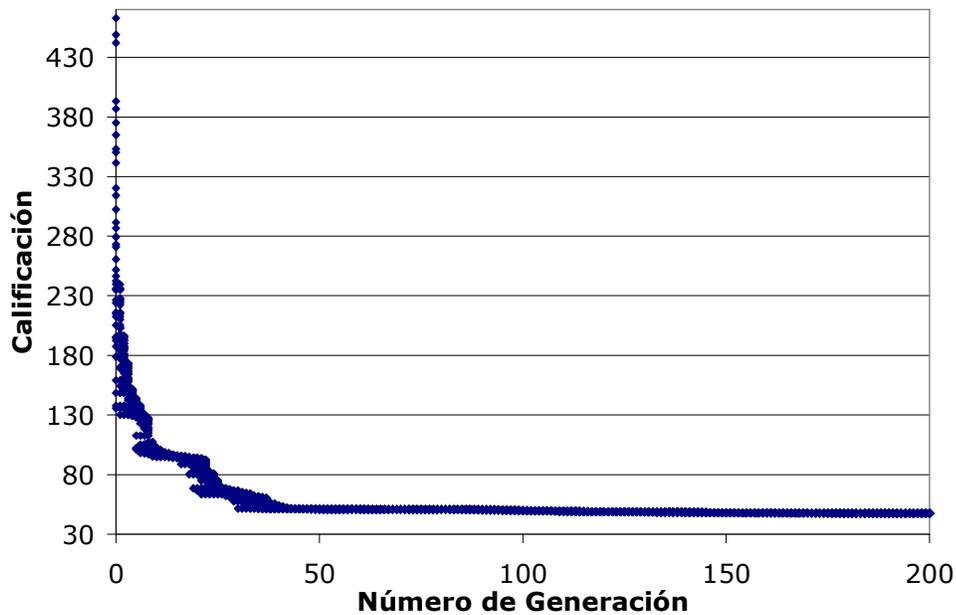


Figura 5.4. Evolución de la Calificación de los Individuos dentro de la Generación (Caso 1)

Los parámetros de evaluación para el mejor individuo se muestran en la Tabla 5.4, así mismo en la Tabla 5.5 podemos ver la comparación de los parámetros del mejor individuo de la ejecución con los de la celda de referencia. Se observa que es un individuo con menor enriquecimiento que el de la celda de referencia, con la k-infinita deseada y un PPF inferior.

	Valor
Número de generación	198
Número de identificador	20700
Enriquecimiento	4.0923%
Concentración de gadolinia	0.8152%
Factor Pico de Potencia a 0 MWd/t	1.362
k-infinita a 0 MWd/t	1.04978
Calificación	47.3612

Tabla 5.4. Valores de los Parámetros del Mejor Individuo (Caso 1)

	k_{inf}	PPF	Enriquecimiento
Celda de referencia	1.04370	1.424	4.1%
Mejor individuo	1.04978	1.362	4.0923%

Tabla 5.5. Comparación de los Parámetros del Mejor Individuo y la Celda de Referencia (Caso 1)

A continuación se muestra el mapa del mejor individuo, Figura 5.5, que perteneció a la generación 198 y tiene como identificador el número 20700.

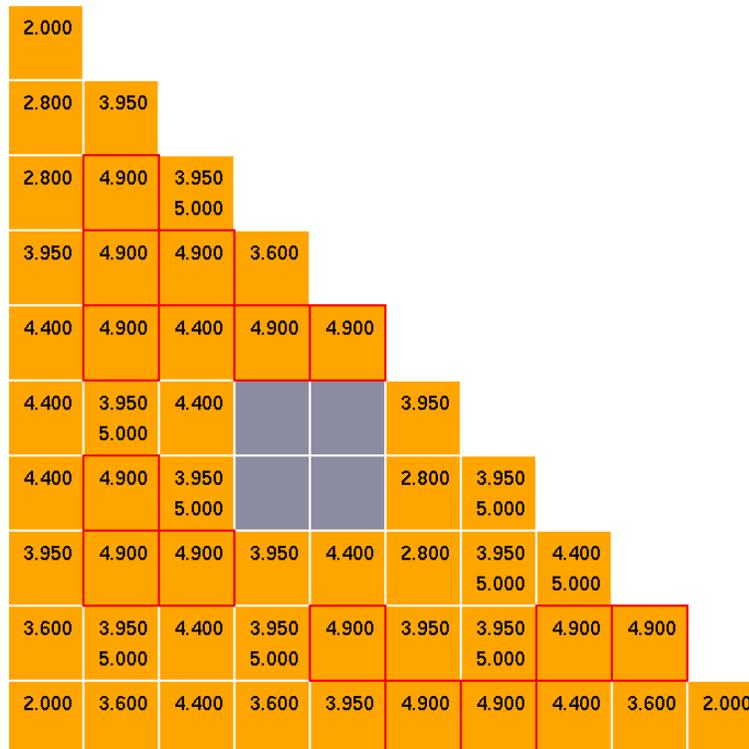


Figura 5.5. Mapa del Mejor Individuo (Caso 1)

En la Tabla 5.6 se muestran los valores menor y mayor de cada parámetro, encontrados para la población de los 40 individuos de la última generación (Número 200). Esto muestra que ha sido posible encontrar 40 individuos con muy buenas características.

		Valor menor	Valor mayor
Enriquecimiento (%)	E	4.0782	4.0989
Concentración de gadolinia (%)	G	0.8152	0.8152
Factor de Pico de Potencia a 0 MWd/t	PPF	1.361	1.364
k-infinita a 0 MWd/t	K_0	1.0488	1.0506

Tabla 5.6. Valores de los Parámetros de la Última Generación

Una parte importante en los procesos de optimización es el tiempo que éste requiere para realizar la búsqueda. La etapa del proceso de optimización que consume el mayor tiempo es la evaluación del simulador neutrónico, CASMO. Para este caso el tiempo de ejecución de los resultados mostrados se calcula de la siguiente manera:

Seis segundos por cada evaluación de CASMO, se realizaron 21058 evaluaciones dando un total de 35.096 horas

Cómo se mencionó en el capítulo 3 una característica importante de los algoritmos genéticos es la búsqueda en paralelo, las siguientes gráficas muestran la presencia de esta característica en la ejecución al observarse el amplio campo de búsqueda (Figuras 5.6 y 5.7).

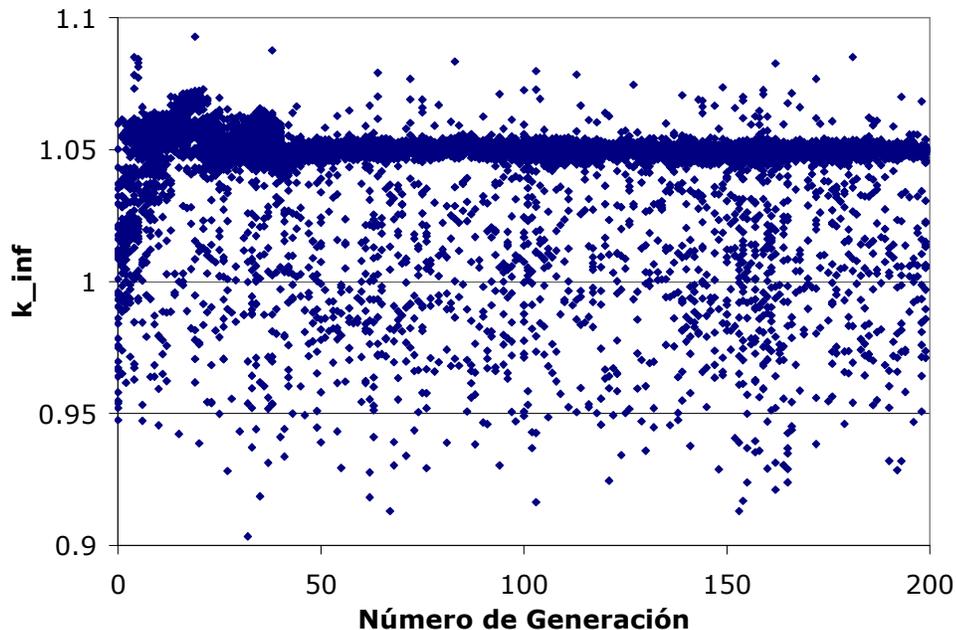


Figura 5.6 Espacio de Búsqueda para el Parámetro de k_{inf} (Caso 1)

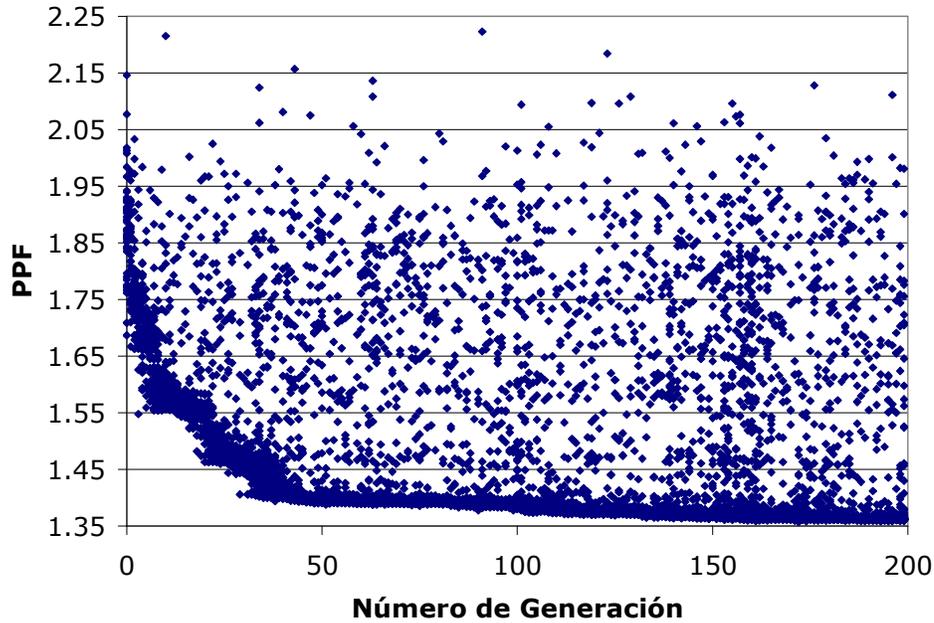


Figura 5.7 Espacio de Búsqueda para el Parámetro de PPF (Caso 1)

Una vez obtenido el mejor individuo, se preparó su archivo de entrada de CASMO para realizar una simulación completa, esto es, a diferentes pasos de quemado. En la Figura 5.8 y 5.9 se presentan las gráficas de k_{∞} y PPF, respectivamente, en función del quemado para el mejor individuo (20700) y para la celda de referencia que se utilizó para definir los valores *objetivo* y límite de los diferentes parámetros de evaluación que aparecen en la Tabla 5.1.

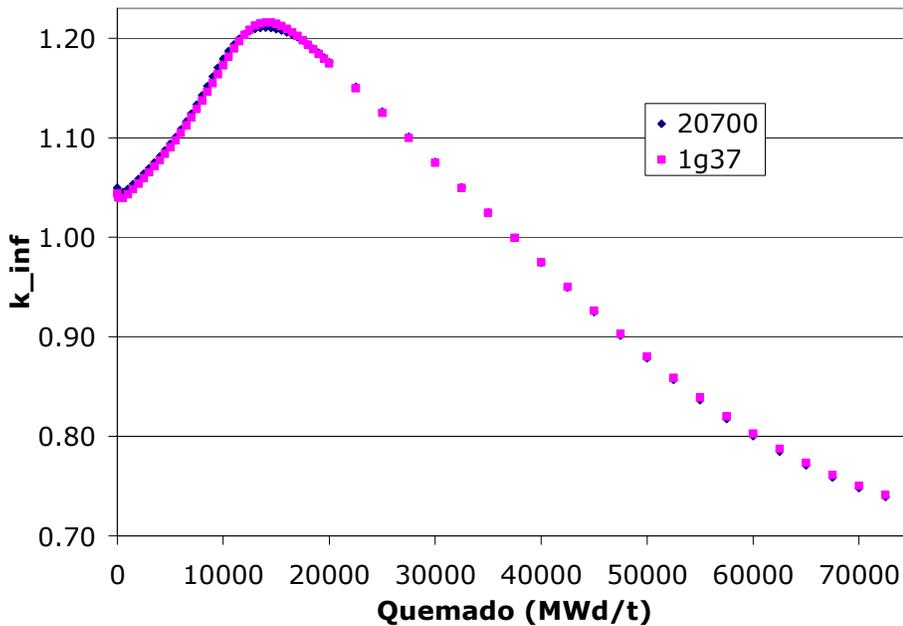


Figura 5.8. Comparación de las Curvas de k_{∞} en Función del Quemado (Caso 1)

Cuando se quema hasta 75,000 MWd/t (MegaWatts-día por tonelada), se observa que la evolución del factor de multiplicación infinita con el quemado, es muy similar al de la celda de referencia aún cuando se tiene un menor enriquecimiento (Figura 5.9). Esto demuestra que fue suficiente considerar solamente el quemado 0 MWd/t y que fue muy útil buscar que el enriquecimiento no bajara indefinidamente durante el proceso de optimización.

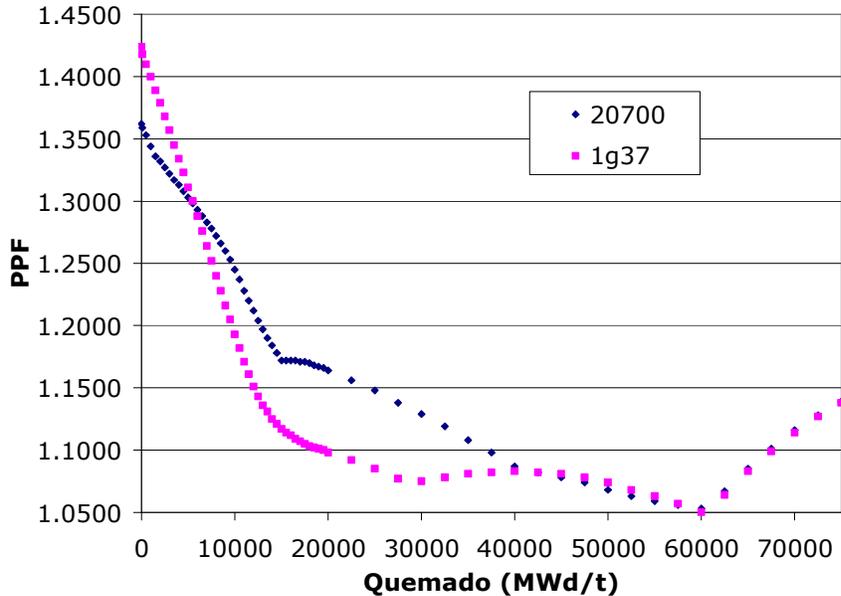


Figura 5.9 Comparación de las Curvas de PPF en Función del Quemado (Caso 1)

Cabe señalar que la evolución del PPF con el quemado tiene mejor comportamiento en la celda 1G37 que en la que se diseñó en este trabajo; se observa que a quemados intermedios el PPF de la 1G37 son menores que para la celda diseñada aquí.

Para completar el análisis, para el mejor individuo se calcularon las curvas de k-infinita y de PPF en función del quemado, para 0, 0.40 y 0.70 fracciones de vacíos en el refrigerante y los resultados se muestran en las Figura 5.10 y 5.11 respectivamente.

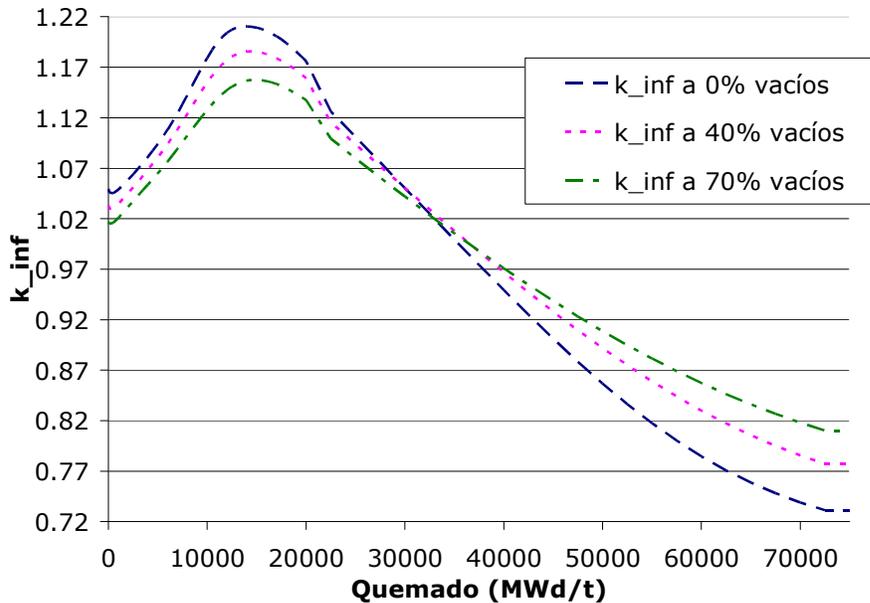


Figura 5.10. Curva de k-infinita en Función del Quemado para el Mejor Individuo a Diferentes Vacíos (Caso 1)

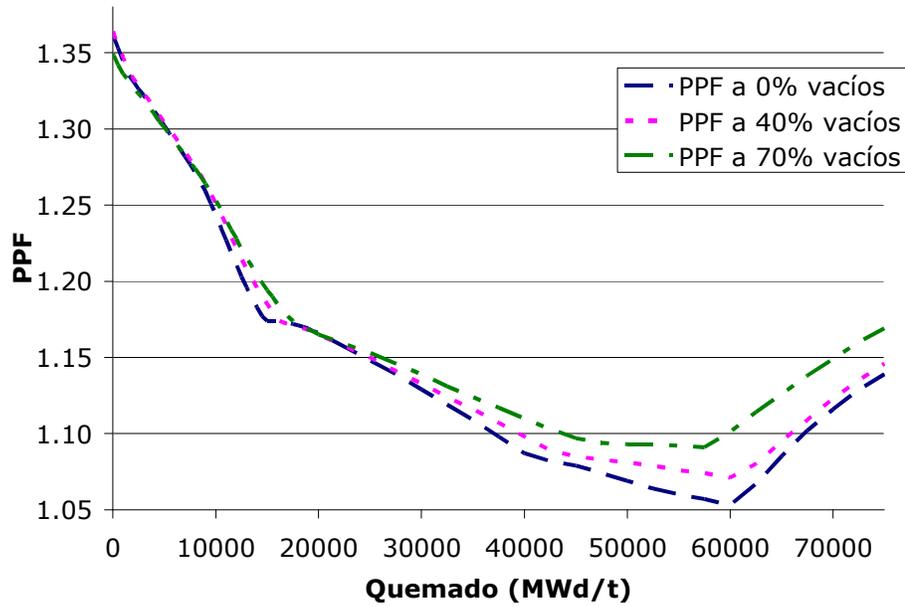


Figura 5.11. Curva de PPF en Función del Quemado para el Mejor Individuo a Diferentes Vacíos (Caso 1)

CASO 2

Con la finalidad de observar el desempeño del algoritmo se procedió a realizar otra comparación, en esta ocasión se tomó como referencia la celda identificada como 1G38 que es utilizada en la parte inferior de un lote de combustible de la CNLV. Se trata de una celda con el mismo enriquecimiento promedio que la 1G37 pero que contiene menor concentración de gadolinia y por consiguiente es más reactiva que 1G37 y tiene un PPF menor. En la Tabla 5.7 se muestran los valores *objetivo* y los valores límite empleados para este segundo caso de aplicación. Los cálculos neutrónicos se realizaron en condiciones de plena potencia y 0% de vacíos.

Variable	E_{max}	E_{min}	E_{ref}	$G_{objetivo}$	G_{max}	G_{min}	$K_{inf\ objetivo}$	PPF_{max}
Valor	4.15%	3.87%	4.1%	0.6413%	0.6461%	0.6261%	1.09199	1.414

Tabla 5.7. Valores *Objetivo* y Valores Límite para los Parámetros (Caso 2)

En la Figura 5.12 se muestra la evolución del enriquecimiento promedio de los individuos de cada generación. El valor se mantuvo dentro de los rangos que se marcan en la Tabla 5.3 y al final del proceso de optimización se obtuvo un valor inferior al de la celda de referencia lo cual era lo buscado. Otra de las metas que se pudo cumplir es el de que la población tenga un promedio de gadolinia establecido ($G_{objetivo}$).

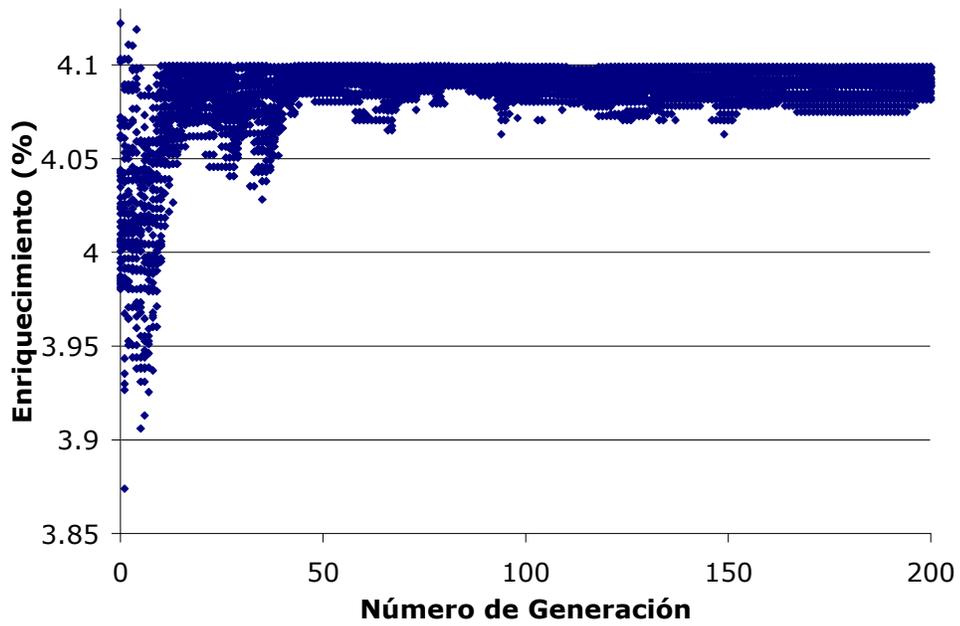


Figura 5.12. Evolución del Enriquecimiento para los Individuos dentro de la Generación (Caso2)

El parámetro que se muestra en la Figura 5.13 es el de k-infinita. Este parámetro evolucionó hacia el valor buscado (*kinf_objetivo*)

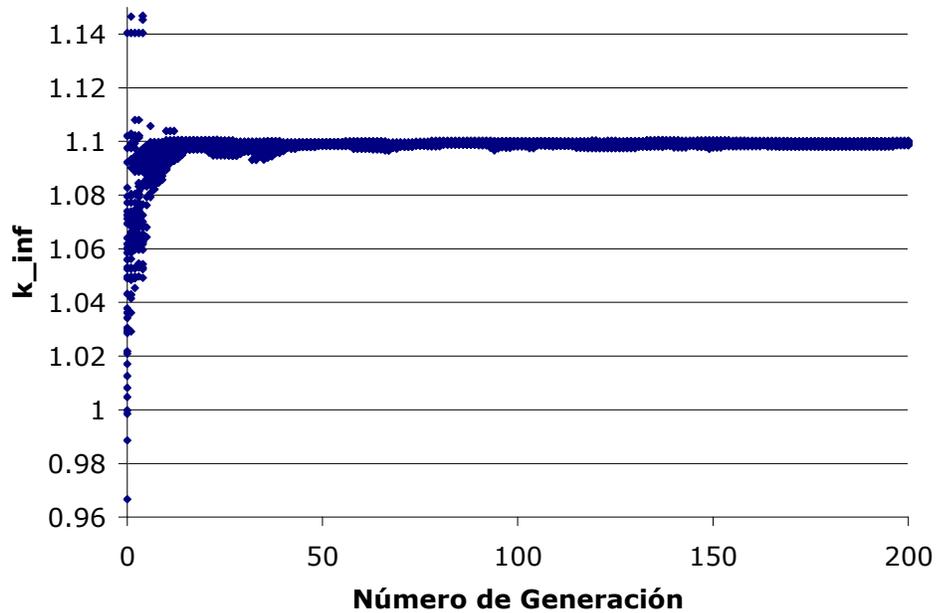


Figura 5.13. Evolución de k_inf para los Individuos dentro de la Generación (Caso2)

En la Figura 5.14, se grafica el valor del PPF que fue definido en la Tabla 5.3 y que también evolucionó disminuyendo hasta llegar a un valor inferior al límite de PPF_{max} .

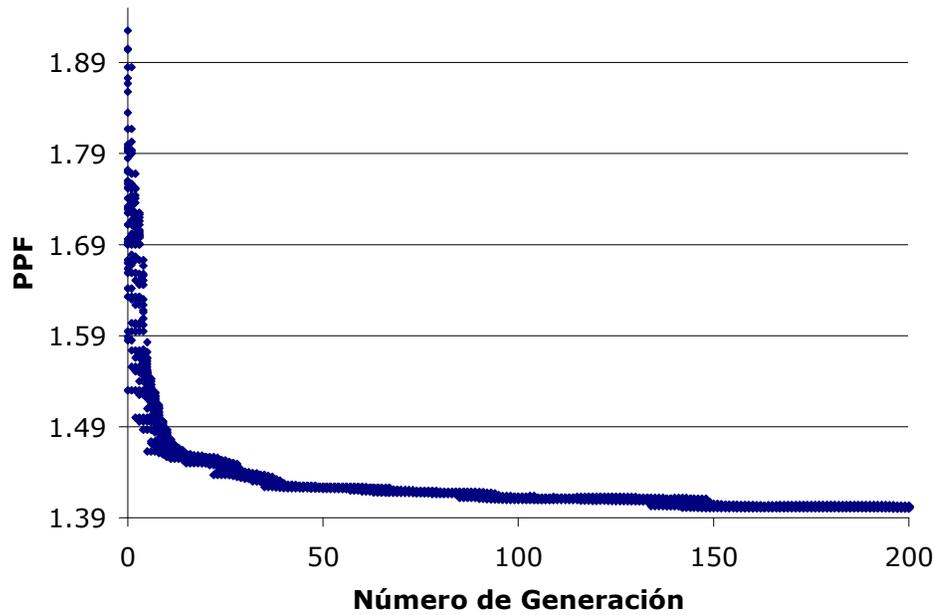


Figura 5.14. Evolución del PPF de los Individuos dentro de la Generación (Caso 2)

Igualmente, se logró minimizar el valor de la calificación que proporcionaba la función objetivo $F(x)$, ecuación 4.1, y que se puede apreciar en la siguiente gráfica, Figura 5.15, en donde se observa que en general la calificación va disminuyendo conforme se avanza en el número de generación.

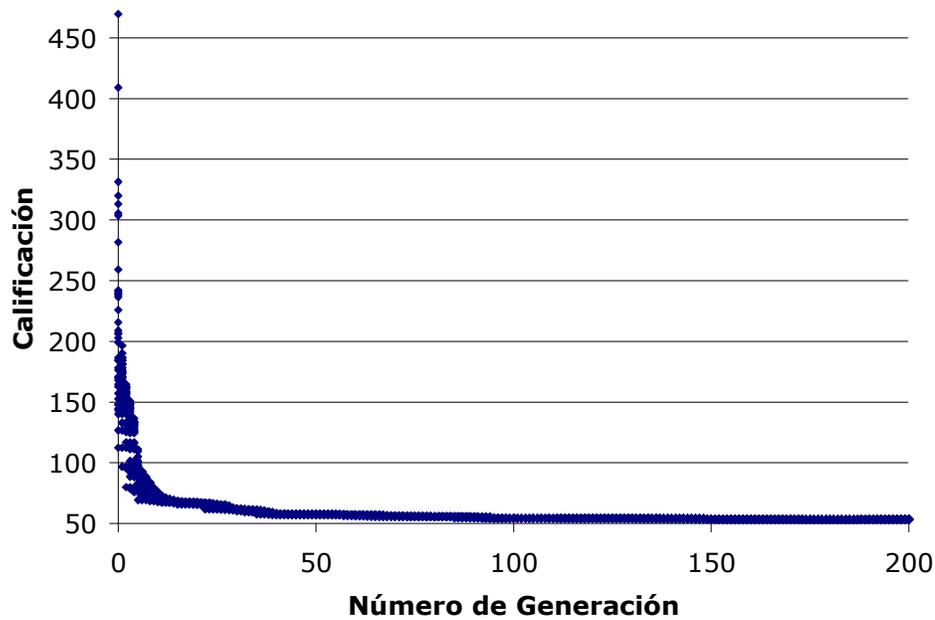


Figura 5.15. Evolución de la Calificación de los Individuos dentro de la Generación (Caso 2)

A continuación se muestran los resultados del mejor individuo, el cual perteneció a la generación 161 y tiene como identificador el número 15244. Los parámetros de evaluación para el mejor individuo se muestran en la Tabla 5.8, así mismo en la Tabla 5.9 podemos ver la comparación de los parámetros del mejor individuo de la ejecución con los de la celda de referencia.

	Valor
Número de generación	161
Número de identificador	15244
Calificación	53.380767

Tabla 5.8. Valores de los Parámetros del Mejor Individuo (Caso 2)

	k_{inf}	PPF	Enriquecimiento	Gadolinia
Celda de referencia	1.09199	1.414	4.1%	0.6413%
Mejor individuo	1.09966	1.401	4.092391%	0.6413%

Tabla 5.9. Comparación de los Parámetros del Mejor Individuo y la Celda de Referencia (Caso 2)

En la Tabla 5.16 se muestran los valores menor y mayor de cada parámetro, encontrados para la población de los 40 individuos de la última generación (Número 200). Esto muestra que ha sido posible encontrar 40 individuos con muy buenas características.

		Valor menor	Valor mayor
Enriquecimiento (%)	E	4.081522	4.098913
Concentración de gadolinia (%)	G	0.641304	0.641304
Factor de Pico de Potencia a 0 MWd/t	PPF	1.4	1.403
k-infinita a 0 MWd/t	K_0	1.09943	1.09966

Tabla 5.10. Valores de los Parámetros de la Última Generación

También para este individuo se preparó su archivo de entrada de CASMO para realizar una simulación completa, esto es a diferentes pasos de quemado. En la Figura 5.16 y 5.17 se presentan las gráficas de k-infinita y PPF, respectivamente, en función del quemado para el mejor individuo (15244) y para la celda de referencia que se utilizó para definir los valores *objetivo* y límite de los diferentes parámetros de evaluación que aparecen en la Tabla 5.1.

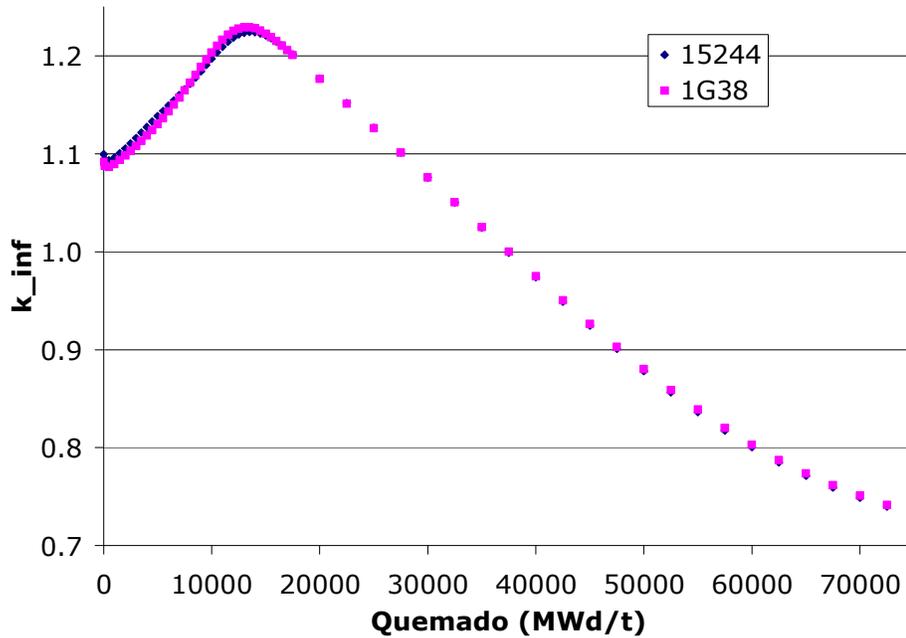


Figura 5.16. Curva de k-infinita en Función del Quemado para el Mejor Individuo (Caso 2)

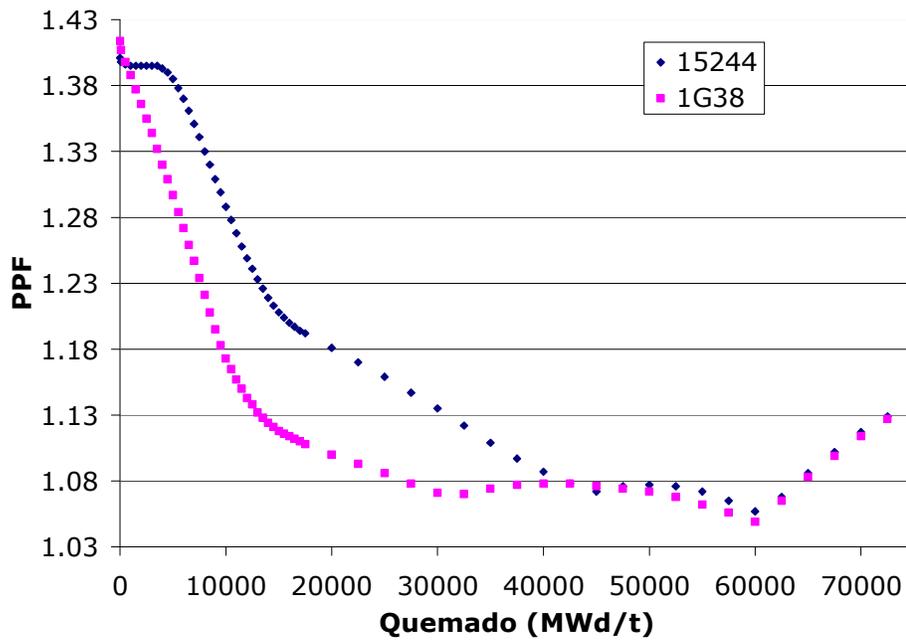


Figura 5.17. Curva de PPF en Función del Quemado para el Mejor Individuo (Caso 2)

Se observa que para quemados intermedios, el PPF de la celda de referencia es menor que el de la celda que se obtuvo como mejor diseño a partir del proceso de optimización (Figura 5.19). Por lo que se puede decir que la celda de referencia en este aspecto es mejor que la que se diseñó en este trabajo.

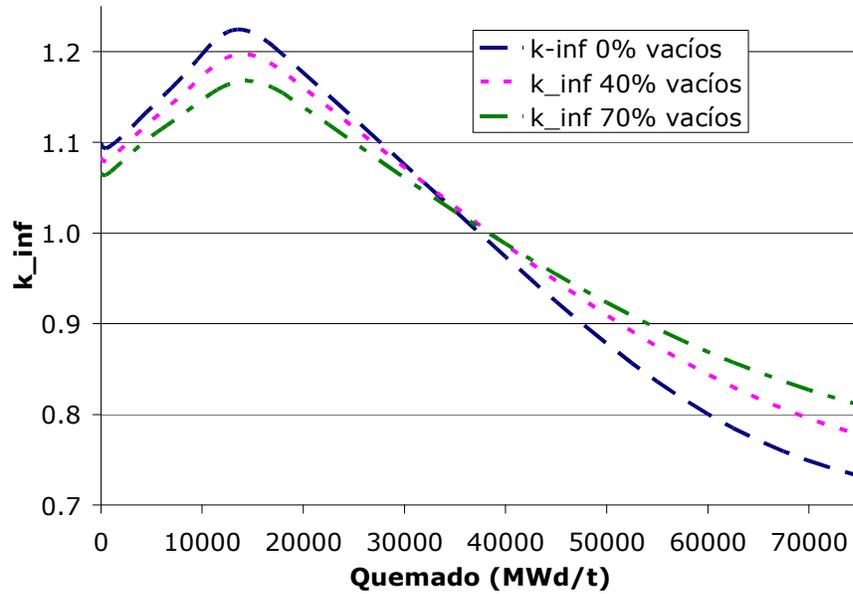


Figura 5.18. Curva de k-infinita en Función del Quemado para el Mejor Individuo a Diferentes Fracciones de Vacío (Caso 2)

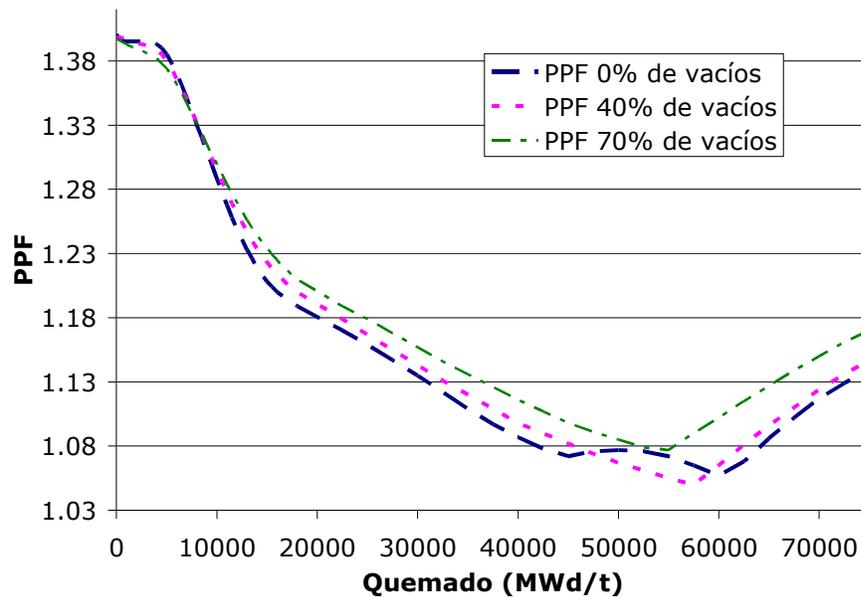


Figura 5.19 Curva de PPF en Función del Quemado para el Mejor Individuo a Diferentes Fracciones de Vacío (Caso 2)

Todos los cálculos que se hicieron para el caso 1 fueron realizados también para el Caso 2 y se pueden obtener prácticamente las mismas observaciones por lo que sus gráficas no son presentadas.

A continuación se presenta un análisis del comportamiento del algoritmo genético cuando se realizan ejecuciones con datos idénticos, pero que obviamente utilizan números aleatorios distintos.

En las Figura 5.20 y 5.21 se presentan las gráficas del parámetro Calificación de dos ejecuciones adicionales en las que se utilizan los datos del Caso 1. Se observa que el algoritmo dirige bien la búsqueda y que se obtienen resultados semejantes en las tres ejecuciones del Caso 1 que se han mostrado.

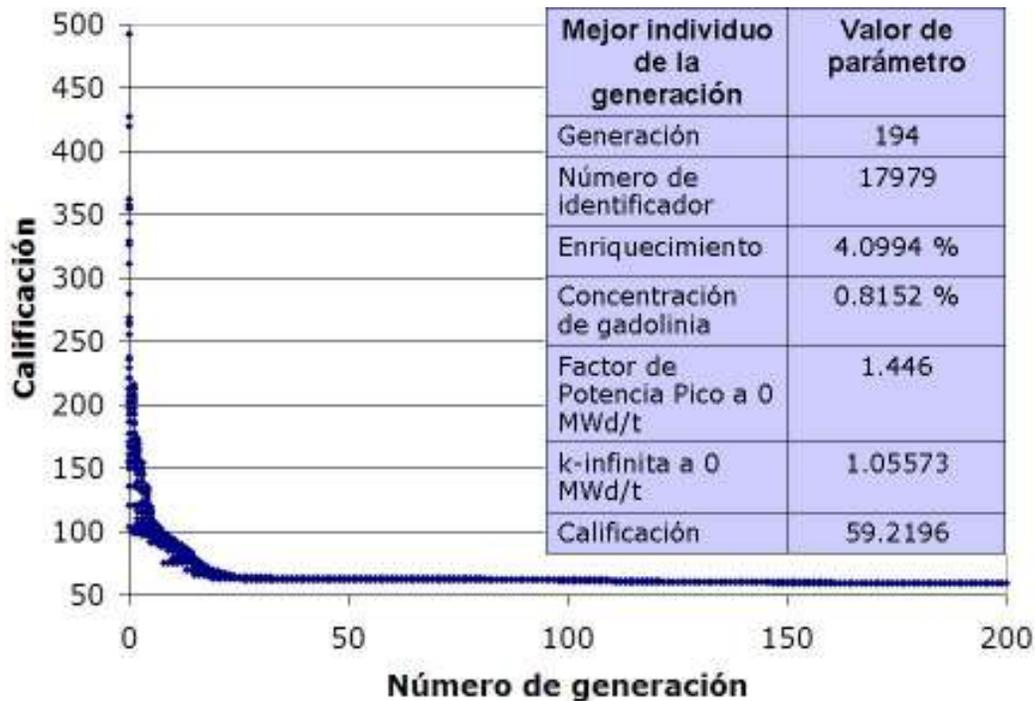


Figura 5.20. Gráfica de Calificación de la Ejecución 20040_0207080026 (Caso 1)

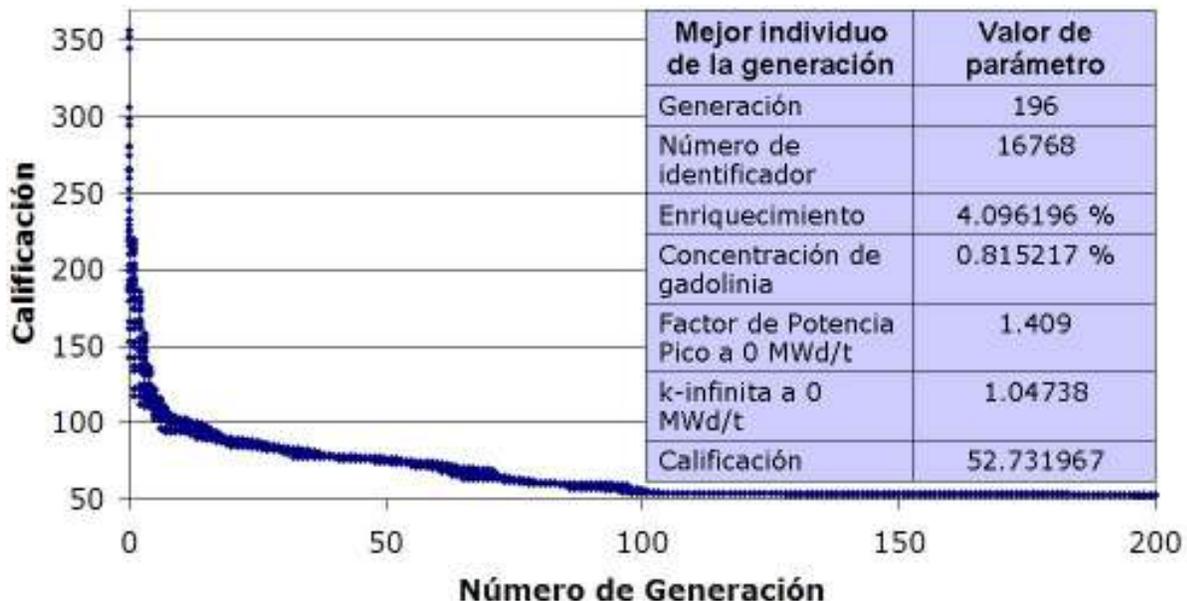


Figura 5. 21. Gráfica de Calificación de Otra Ejecución (Caso 1)

Por último, se muestran las gráficas de k-inf y PPF (Figuras 5.22 y 5.23) únicamente para el individuo del Caso 1, que comparan el desempeño neutrónico del mejor individuo (20700) y la celda de referencia (1G37). A diferencia de las gráficas 5.8 y 5.9, estas gráficas también comparan el uso de dos simuladores neutrónicos: HELIOS, un código considerado como de referencia porque resuelve la ecuación de transporte en multigrupos en dos dimensiones

con un detalle muy fino de la geometría, y CASMO, el simulador de preferencia para este trabajo, el cual también resuelve la ecuación de transporte en multigrupos pero con algunas simplificaciones en el tratamiento de la geometría, por lo que se ejecuta en menor tiempo de cómputo. Ambos códigos fueron desarrollados por Studsvik Scandpower y utilizan una biblioteca neutrónica basada en la ENDF/B-VI. Se puede observar que el modelado de CASMO es muy cercano al de HELIOS y se tiene la ventaja de que se ejecuta en sólo 60% del tiempo que requiere HELIOS por lo que sí podemos recomendar el uso de CASMO para las simulaciones neutrónicas de la gran cantidad de individuos que deben ser evaluados durante el proceso de optimización.

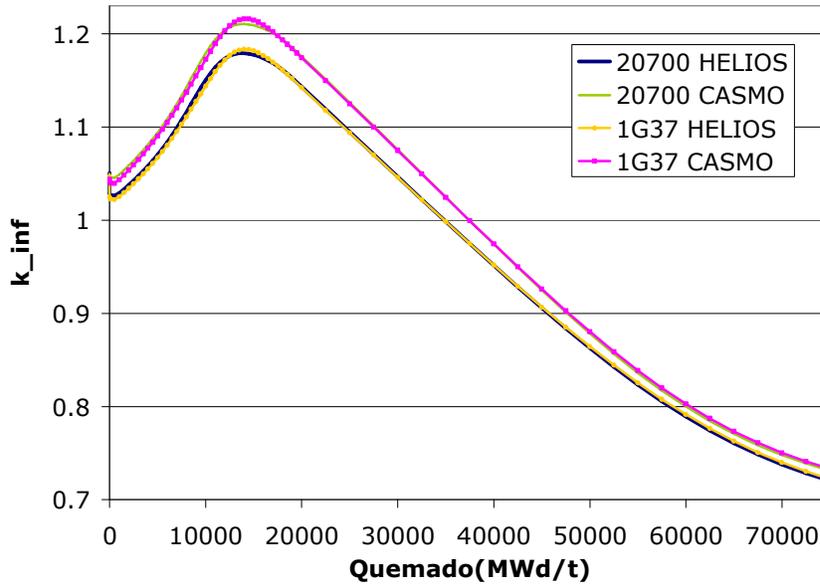


Figura 5.22. Evolución de k_{inf} con el Quemado obtenida con CASMO y HELIOS

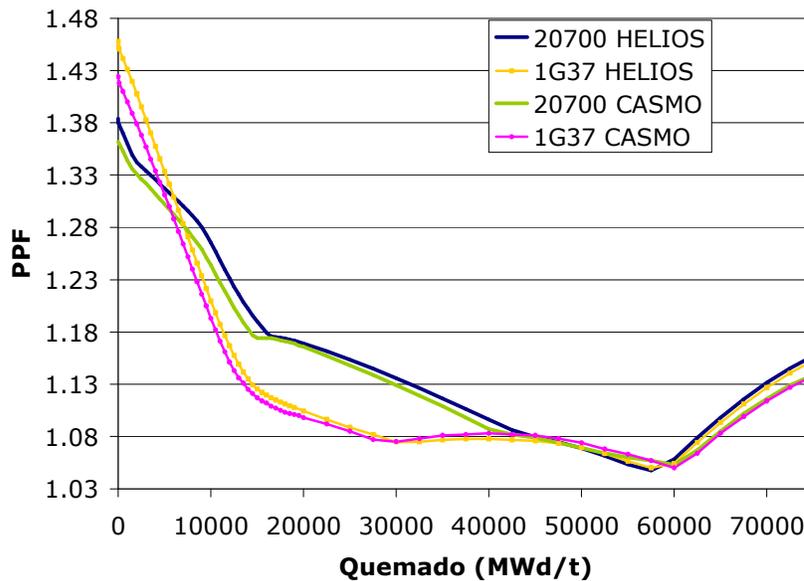


Figura 5.23. Evolución de PPF con el Quemado Obtenida con CASMO y HELIOS

Conclusiones

Se actualizó y mejoró un programa escrito en lenguaje C que aplica el método de los algoritmos genéticos para la optimización del diseño radial de combustible para un BWR. Las semejanzas en el combustible y en el núcleo de un ABWR y un BWR hacen que este trabajo sea aplicable para el reactor BWR avanzado. Las mejoras al programa de optimización hacen más eficiente la organización y representación de los resultados. Además, para este trabajo se utilizó como simulador neutrónico CASMO-4 el cual se ejecuta en un tiempo menor que el simulador HELIOS utilizado anteriormente, esto ayudó a incrementar la rapidez de ejecución de la optimización, ya que los resultados de la evaluación de cada individuo se obtuvieron en sólo 60% del tiempo empleado por HELIOS. Con el fin de aprovechar todos los datos generados, el programa de optimización también guarda todos los archivos de entrada de CASMO-4, de esta manera pueden volverse a utilizar o ser modificados dependiendo de las necesidades del usuario.

Tomando en cuenta las diferencias entre los códigos CASMO-4 y HELIOS para los valores del PPF y del factor de multiplicación infinita de una celda de referencia, se ajustaron los parámetros que intervinieron en la función objetivo que se utiliza cuando CASMO-4 es empleado como simulador. La utilización de pesos con valores flexibles en la función objetivo permite acelerar la búsqueda hacia zonas más adecuadas al penalizar con mayor o menor intensidad el parámetro que se aleja o acerca al valor deseado. El proceso de optimización se ejecutó varias veces, en todas ellas el proceso funcionó adecuadamente minimizando la función objetivo. Estas ejecuciones sirvieron para ajustar los pesos que se asignaron a los diferentes parámetros de la función objetivo y para ajustar los parámetros del algoritmo genético. Con base en dichas ejecuciones, puede notarse la adecuada asignación de valores para el número de generaciones, el tamaño de la población y las probabilidades de cruzamiento y mutación.

Con el objeto de reducir el tiempo de cálculo sin disminuir de manera considerable la probabilidad de explorar ampliamente el espacio de búsqueda que puede favorecer a las soluciones más adecuadas, se instrumentaron varias reglas de acomodo geométrico de los tipos de barra de combustible y viendo los resultados se puede concluir que esas reglas fueron apropiadas. Entre las reglas utilizadas, se definieron ventanas de valores posibles tanto para el enriquecimiento promedio como para la concentración de gadolinia promedio en las soluciones candidatas. Este recurso restringió la evaluación de individuos que al tener enriquecimientos muy bajos podrían cumplir satisfactoriamente con la función objetivo pero que en una evaluación completa, a diferentes pasos de quemado, difícilmente cumplirían los requerimientos de reactividad.

Una simplificación más en el proceso de optimización fue que se decidió no evaluar cada celda para diferentes quemados, sino que únicamente se evaluó neutrónicamente a cero quemado. Con esta simplificación se ahorró una cantidad de tiempo considerable. Sin embargo, se verificó que la evolución de los parámetros neutrónicos con el quemado del combustible era la adecuada a pesar de que la celda óptima encontrada provenía de una optimización basada únicamente en evaluaciones a cero quemado. Esto se hizo aprovechando las características del programa de optimización, ya que usando el archivo de entrada de CASMO-4 para el mejor individuo se realizó la evaluación a diferentes pasos de quemado.

Dentro de las ejecuciones, además de las realizadas con el fin de afinar los pesos y términos de la función objetivo, y los parámetros del algoritmo genético, se realizaron ejecuciones para dos casos de referencia con parámetros neutrónicos diferentes. Esto requirió de redefinir los valores objetivo, con base en la ejecución de CASMO-4 de la nueva referencia. Ambos casos demostraron el correcto desempeño del algoritmo y en general del proceso de optimización.

Con los resultados obtenidos, el mejor individuo de la ejecución fue utilizado para generar la biblioteca neutrónica que puede ser usada con SIMULATE para el modelado en estado estable del núcleo completo. De esta manera se podría hacer una simulación de un ABWR usando la biblioteca neutrónica generada en este trabajo.

Como ya se comentó, las diferentes etapas de gestión de combustible dentro del núcleo se caracterizan por ser problemas de optimización que presentan alta dimensionalidad combinatoria, no lineales y que requieren un uso intensivo de capacidad computacional. Si bien estas etapas no son independientes entre sí, este trabajo sólo se enfocó al problema de la optimización radial sin tomar en cuentas las demás etapas. Teniendo esto presente, los algoritmos genéticos demostraron ser una muy buena opción para resolver el problema de la optimización radial de combustible. En particular, la aplicación obtuvo resultados que no sólo pueden apreciarse en la obtención del mejor individuo, sino que con toda la última generación ya que se trata de cuarenta individuos con mejores parámetros neutrónicos que la celda de referencia para ambos casos estudiados.

Este trabajo deja la puerta abierta a la inclusión de más detalles en la función objetivo y un continuo refinamiento de los pesos y los parámetros utilizados, además de prestarse para la integración de las demás etapas de diseño.

Acrónimos

ABWR	Advanced Boiling Water Reactor	Reactor Avanzado de Agua en Ebullición
ADS	Automatic Depressurization System	Sistema de Despresurización Automática
AG		Algoritmos Genéticos
APF	Axial Peak Factor	Factor de Pico Axial
BWR	Boiling Water Reactor	Reactor de Agua en Ebullición
CA		Corriente Alterna
CNLV		Central Núcleo-Eléctrica Laguna Verde
CPR	Critic Power Ratio	Tasa de Potencia Crítica
CS	Core Support	Soporte del Núcleo
ECCS	Emergency Core Cooling System	Sistema de Refrigeración de Emergencia del Núcleo
HPCF	High Pressure Core Flooding System	Sistema de Inundación del Núcleo de Alta Presión
HPCIS	High Pressure Coolant Injection System	Sistema de Inyección de Refrigerante (de Seguridad) de Alta Presión
LPCI	Low Pressure Coolant Injection	Inyección de Refrigerante de Baja Presión
LPF	Local Peak Factor	Factor de Pico Local
LPFL	Low Pressure Flooder	Inundador de Baja Presión
MCPR	Minimum Critical Power Ratio	Mínima Razón de Potencia Crítica
MLHGR	Maximum Linear Heat Generation Rate	Máxima Razón de Generación de Calor Lineal
MOX	Mixed Oxide	Oxidos Mixtos
PBC		Patrones de Barras de Control
PWR	Pressurized Water Reactor	Reactor de Agua a Presión

RCCV	Reinforced Concrete Containment Vessel	Vasija de Contención de Concreto Reforzado
RCIC	Reactor Core Isolation Cooling	Sistema de Refrigeración del Núcleo Aislado
RCS	Reactor Core Spray	Sistema de Rocío al Núcleo
RHRS	Residual Heat Removal System	Sistema de Evacuación del Calor Residual
RIP	Reactor Internal Pump	Bomba Interna del Reactor
RPF	Radial Peaking Factor	Factor de Pico Relativo o Radial
RWCUS	Reactor Water Cleanup System	Sistema de Purificación y Limpieza de Agua del Reactor
SCRAM		Disparo o parada rápida del reactor; parada brusca del reactor mediante la inserción manual o automática de las barras de control, para evitar o minimizar las consecuencias de una condición considerada peligrosa.
SLCS	Standby Liquid Control System	Sistema de Control de Líquido de Reserva
TAC		Tanques de Almacenamiento de Condensados
TPF	Total Peak Factor	Factor de Pico Total
VVER	Vodo-Vodyanoi Energetiche Reactor	Reactor a Presión de Agua-Agua

Bibliografía

- Alim F., Ivanov K., "Genetic Algorithm Development for in-Core Fuel Management", *ANS 2004 Annual Meeting*, June 13-17 (2004).
- Bäck, T., Hammel, U. and Schwefel, P. "Evolution Computation: Comments on the History and Current State". *IEEE Transactions of Evolutionary Computation*, 1, 3-17 (1997).
- Bäck, Thomas. Optimal Mutation Rates in Genetic Search. In Stephanie Forrest, editor, *Proceedings of the Fifth International Conference on Genetic Algorithms*, pages 2–8. Morgan Kaufmann Publishers, San Mateo, California, July 1993.
- Baker, James Edward. Adaptive Selection Methods for Genetic Algorithms. In John J. Grefenstette, editor, *Proceedings of the First International Conference on Genetic Algorithms*, pages 101–111. Lawrence Erlbaum Associates, Hillsdale, New Jersey, July 1985.
- Bickle, T. and Thiele, L. "A Comparison of Selection Schemes used in Evolutionary Algorithms", *Evolutionary Computation*, 4, 361-394 (1996).
- Blanco Anibal, Apuntes de Física de Reactores, Instituto Balseiro
Pagina de Internet:
<http://ib.cnea.gov.ar/~fr/>
- Boiling Water Reactor (BWR) System, Reactor Concepts Manual, USNRC Technical Training Center, Rev 0200.
- Coello Coello, Carlos A. Introducción a la Computación Evolutiva (Notas de Curso), Departamento de Ingeniería Eléctrica Sección de Computación, mayo 2003.
- Coello, Carlos. "An updated survey of GA-based multiobjective optimization techniques" *ACM Computing Surveys*, vol.32, no.2, p.109-143 (junio de 2000).
- Collins, J. "Studies in Artificial Evolution". PhD Thesis, University of California, 1992
- Cuevas G. et al, "Optimization of MOX Enrichment Distributions in Typical LWR Assemblies Using a Simplex Method-Based Algorithm", *Annals of Nuclear Energy* 29 (17) 2001-2017 (2002).
- Dawkins, Richard. *The Blind Watchmaker: Why the Evidence of Evolution Reveals a Universe Without Design*. W.W. Norton, 1996.
- De Jong, A. K. An Analysis of the Behavior of a Class of Genetic Adaptive Systems. PhD Thesis, University of Michigan, 1975.
- Deb, K., "An efficient Constraint Handling Method for Genetic Algorithms", *Comp. Meth. Appl. Mech.Eng.*, 186, 311-338 (2000).
- Eshelman, Larry J., Richard A. Caruana, and J. David Schaffer. Biases in the Crossover Landscape. In J. David Schaffer, editor, *Proceedings of the Third International Conference on Genetic Algorithms*, pages 10–19, San Mateo, California, 1989. Morgan Kaufmann Publishers.
- Fogarty, Terence C., Varying the Probability of Mutation in the Genetic Algorithm. In J. David Schaffer, editor, *Proceedings of the Third International Conference on Genetic Algorithms*, pages 104–109, San Mateo, California, 1989. Morgan Kaufmann Publishers.

- Forrest, Stephanie. "Genetic algorithms: principles of natural selection applied to computation." *Science*, vol.261, p.872-878 (1993).
- François Lacouture Juan Luis, Lopez Héctor Arnoldo, "SOPRAG: a system for boiling water reactors reload pattern optimization using genetic algorithms", *Annals of Nuclear Energy* 26 (12), 1053-1063 (1999).
- François Lacouture Juan Luis, Martin del Campo Márquez Cecilia, François Martin del Campo Ramiro, Morales Luis, "A Practical Optimization Procedure for Radial BWR Fuel Lattice Design Using Tabu Search with a Multiobjective Function", *Annals of Nuclear Energy* 30 (12) 1213-1229 (2003).
- Gen, M and Cheng, R., "Genetic Algorithms & Engineering Optimisation". Wiley Series in Engineering Design and Automation. John Wiley & Sons, New York, 2000.
- Gen, M., Genetic Algorithms and Engineering Design, Wiley & Sons, Inc. New York (1996).
- Glover, F; Laguna, M. Tabu Search. 6th Ed. Kluwer Academic Publishers. 2002.
- Goldberg, David E., *Genetic Algorithms in Search, Optimization, and Machine Learning*. Addison-Wesley Publishing Co., Reading Massachusetts 1989.
- Guler C., S. Levine, K. Ivanov, J. Svarny, V. Krysl, P. Mikolas,, J. Sustek, , "Development of the VVER Core Loading Optimization System", *Annals of Nuclear Energy* 31 (7) 747-772 (2004).
- Haraguchi Hiroko, Iwashita Yoshiri, Yoshioka Toshiro, Koyana Junichi, Yamanaka Akihiro, Nakamura Mitsunari, Haikawa Katsumasa, Inicial core of nuclear power plant, Hitachi LTD, Tokio Japan, Patern number 5631939, Mayo 20 1997
- Haupt, Randy y Sue Ellen Haupt. *Practical Genetic Algorithms*. John Wiley & Sons, 1998.
- Hirano Y. et al, "Optimization of Fuel Rod Enrichment Distribution for BWR Fuel Assembly". *Proceedings of the International Conference on the Physics of Reactors*, Japan Atomic Research Institute & Power Reactor & Nuclear Fuel Development Co. Vol. 1, B45-B53 (1996).
- Holland, John H. *Adaptation in Natural and Artificial Systems*. Ann Harbor: University of Michigan Press, 1975.
- Holland, John. "Genetic algorithms" *Scientific American*, julio de 1992, p. 66-72.
- Homaifar A, S. H. Y. Lai, and X. Qi. Constrained Optimization via Genetic Algorithms. *Simulation*, 62(4):242-254, 1994.
- Kobayashi Yoko, Aiyoshi Eitaro, Optimization of Boiling Water Reactor Loading Pattern Using and Improved Genetic Algorithm, Proceedings of the 2001 IEEE International Symposium on Intelligent Control September 5-7, Mexico City, Mexico
- Koza, John, Forest Bennett, David Andre y Martin Keane. *Genetic Programming III: Darwinian Invention and Problem Solving*. Morgan Kaufmann Publishers, 1999.
- Koza, John, Martin Keane, Matthew Streeter, William Mydlowec, Jessen Yu y Guido Lanza. *Genetic Programming IV: Routine Human-Competitive Machine Intelligence*. Kluwer Academic Publishers, 2003.

- Lashon B. Booker. Improving Search in Genetic Algorithms. In Lawrence Davis, editor, Genetic Algorithms and Simulated Annealing. Morgan Kaufmann Publishers, San Mateo, California, 1987.
- Lashon B. Booker. Intelligent Behavior as an Adaptation to the Task Environment. PhD thesis, Logic of Computers Group, University of Michigan, Ann Arbor, Michigan, 1982.
- LE Fennern, ABWR Seminar –Reactor, Core & Neutronics, April 13, 2007, General Electric.
- Lim E.Y., Leonard A., "Optimal Pin Enrichment Distributions in Boiling Water Reactor Fuel Bundles", *Nuclear Science and Engineering* 64, 694-708 (1977).
- Lohman, R., Applications of Evolution Strategy in Parallel Population. In Parallel Problem Solving from Nature – PPSN I, pp. 198-208, 1991.
- Maldonado G. I., Guo T., Engrand P., "Dual-Objective Simulated Annealing Applied to Within-Lattice Loading Optimization", *Trans. American Nuclear Soc.* 78, 236,(1998).
- Martín del Campo Máquez Cecilia, François Lacouture Juan Luis, Carmona Hernández Roberto, Oropeza Camargo Ivonne Patricia, "Optimization of BWR fuel lattice enrichment and gadolinia distribution using genetic algorithms and knowledge", *Annals of Nuclear Energy* 34 (2007) 248–253 (2007).
- Martín del Campo Máquez Cecilia, François Lacouture Juan Luis, López Héctor Arnoldo, "AXIAL: a system for boiling water reactor fuel assembly axial optimization using genetic algorithms", *Annals of Nuclear Energy* 28 (16) 1667-1682 (2001).
- Martín del Campo Máquez Cecilia, François Lacouture Juan Luis,, Palomera Miguel Angel, "Optimización de Celdas de Combustible para BWR basada en Búsqueda Tabú Modificada", *Memorias Congreso Internacional Conjunto Cancún 2004 LAS/ANS-SNM-SMSR/ XV Congreso Anual de la SNM y XXII Reunión Anual de la SMSR*, Cancún, Q. R., México (2004).
- Michalewicz Zbigniew. A Survey of Constraint Handling Techniques in Evolutionary Computation Methods. In J. R. McDonnell, R. G. Reynolds, and D. B. Fogel, editors, Proceedings of the 4th Annual Conference on Evolutionary Programming, pages 135–155. The MIT Press, Cambridge, Massachusetts, 1995.
- Michalewicz Zbigniew. Genetic Algorithms + Data Structures = Evolution Programs. Springer-Verlag, New York, third edition, 1996.
- Mitchell, Melanie. *An Introduction to Genetic Algorithms*. MIT Press, 1996.
- Mitchell, Tom M. The Need for Biases in Learning Generalizations. Technical Report CBM-TR-117, Department of Computer Science, Rutgers University, 1980.
- Página de internet:
<http://postgrado.info.unlp.edu.ar/Carrera/Magister/Redes%20de%20Datos/Tesis/Tesis%20M agnago.pdf>.
- Página de internet:
<http://the-geek.org/docs/algen/>
- Pohlheim, Harmut, "Evolutionary algorithms: Overview, Methods and Operators". Genetic

and Evolutionary Algorithms toolbox for use with Matlab (august 1999)

- Radcliffe, Nicholas J. Forma Analysis and Random Respectful Recombination. In Richard K. Belew and Lashon B. Booker, editors, Proceedings of the Fourth International Conference on Genetic Algorithms, pages 222–229. Morgan Kaufmann Publishers, San Mateo, California, July 1991.
- Sesonske Alexander, Nuclear Power Plant Design Analysis, Technical Information Center Office of Information Center, United States Atomic Energy Comission, 1973
- Studsvik Scanpower, *CASMO-4 A fuel assembly burnup program. User´s manual*, 2004.
- Tanarro Sanz Agustín, Tanarro Onrubia Agustín, Diccionario Ingles-Español sobre Tecnología Nuclear, Foro Nuclear de la Ingeniería Nuclear Española
- Yilmaz S., Ivanov K., Levine S., Mahgerefteh M., "Application of Genetic Algorithm to Optimize Burnable Poison Placement in PWRs", *Annals of Nuclear Energy* 33 (5) 446-456, (2005).