

INSTITUTO TECNOLÓGICO Y DE ESTUDIOS  
SUPERIORES DE MONTERREY  
CAMPUS CIUDAD DE MÉXICO



MODELO PARA TOMA DE DECISIÓN EN PORTAFOLIOS DE  
INVERSIÓN CON ACCIONES USANDO ALGORITMOS GENÉTICOS

DAVID HEBERT DEL VALLE PANIAGUA<sup>Ph</sup>

Ph. D.

JULIO, 2002

## **RESUMEN**

Métodos y técnicas usados en otras áreas se han aplicado para solucionar problemas financieros con el fin de obtener más alternativas de solución. Uno de estos métodos son los Algoritmos Genéticos (AGs).

Los Algoritmos Genéticos (AGs) se han convertido en un método de solución de problemas de optimización muy utilizado debido a su robustez para imitar los mecanismos naturales de evolución y por lo tanto adaptarse a ambientes complejos.

El presente trabajo muestra la aplicación de los Algoritmos Genéticos en un Modelo para ayuda a la toma de decisión en portafolios de Inversión. El modelo considera la selección de portafolios acorde a las preferencias del usuario, en cuanto a riesgo (Varianza) y rendimiento. Los resultados muestran que los algoritmos genéticos pueden ser otra opción para la ayuda en la selección de portafolios de inversión. También muestra que combinado con un modelo de programación lineal mejora sensiblemente sus resultados.

# INDICE

Resumen	
1. Introducción	1
2 .Objetivos	4
3. Marco Teórico	6
3.1 Algoritmos Genéticos	6
3.1.1 Que es un Algoritmo Genético.	8
3.1.2 Supuestos para su modelación:	13
3.1.3 Operadores Genéticos	15
3.1.4 Parámetros Genéticos	16
3.1.5 Aplicaciones:	18
3.2 Algoritmos Genéticos en portafolios de Inversión	19
3.3 Aprendizaje Probablemente aproximadamente Correcto (Probably Approximately Correct Learning- PAC Learning.)	21
3.3.1 Principios	22
3.3.2 Complejidad de la muestra	24
3.3.3 PAC – Tamaño de Población (Population Size)	25
3.4 Portafolios de inversión.	26
3.4.1 Definición: Portafolio de inversión	28
3.4.2 Varianza del portafolio	29
3.4.3 Diversificación y riesgo de un portafolio	30
3.4.4 Modelo de Markowitz	31
3.4.5 Modelo Speranza	33
3.4.6 Capital Asset Pricing Model (CAPM)	34
4. Metodología	35
4.1 Modelación del portafolio con Algoritmos Genéticos	35
4.1.1 4 El Algoritmo Genético	35
4.1.2 Codificación del portafolio con AGs	36
4.1.3 Funciones de aptitud.	37
4.1.4 Correlaciones	42
4.2 Calculo del Tamaño de Población	42
4.3 Descripción del modelo propuesto	47
5. Resultados	51
6. Conclusiones y Recomendaciones	56
6.1 Conclusiones	56
6.2 Recomendaciones	58

7. Trabajos Futuros	59
7.1 Modelado de portafolio con cadenas con en carácter ASCII de 0 a 100	59
7.2 Determinación del número de emisoras que participarán en un portafolio.	61
7.3 Optimización del Manejo de los cromosomas.	62
8. Bibliografía	63
9 Apéndices	73
APENDICE A:Resultados de la corrida en SAS del Modelo propuesto por Speranza. Para el caso de 31 emisoras maximizando Rendimiento	73
APÉNDICE B:Salida propuesta por el modelo de AG. Para el caso de 31 emisoras maximizando Rendimiento	75
APÉNDICE C:Resultados de la corrida en SAS del Modelo propuesto por Speranza. Para el caso de 149 emisoras maximizando Rendimiento	77
APÉNDICE D:Salida propuesta por el modelo de AG. Para el caso de 149 emisoras maximizando Rendimiento	79
APÉNDICE E:Salida propuesta por el modelo de AG. para el resultado de la corrida en SAS del Modelo propuesto por Speranza. Para el caso de 31 emisoras maximizando Rendimiento	83
APÉNDICE F:Resultados de la corrida en SAS del Modelo propuesto por Speranza para el resultado de la salida propuesta por el modelo de AG. Para el caso de 31 emisoras maximizando Rendimiento	86
APÉNDICE G:Salida propuesta por el modelo de AG. para el resultado de la corrida en SAS del Modelo propuesto por Speranza. Para el caso de 149 emisoras maximizando Rendimiento	88
APÉNDICE H:Resultados de la corrida en SAS del Modelo propuesto por Speranza para el resultado de la salida propuesta por el modelo de AG. Para el caso de 149 emisoras maximizando Rendimiento	94
10. Descripción de la aplicación PortAlGe	96
10.1 Requerimientos de la aplicación	96
10.2 Como cargar la aplicación	96
10.3 Hoja de datos	96
10.4 Hoja de Covarianza	97
10.5 Hoja de Correlaciones	98
10.6 Hoja de resultados	99
10.7 Para iniciar la aplicación	100

# 1.INTRODUCCIÓN

En la última década las finanzas han cobrado una importancia como nunca antes, debido a que la globalización afecta a cada individuo de diferente forma, pero con el común denominador de que tiene que buscar el mejor manejo de su capital, esto ha dado como consecuencia que la investigación dentro del área de finanzas se incrementa de manera significativa .

Métodos y técnicas usados en otras áreas se han aplicado para solucionar problemas financieros con el fin de obtener más alternativas de solución. Uno de estos métodos son los Algoritmos Genéticos.

Los Algoritmos Genéticos (AGs) se han convertido en una herramienta muy socorrida en la investigación actual, debido a su velocidad de búsqueda dentro de gran espacio de soluciones debido a su facilidad para imitar el mecanismo natural de evolución (Wen-Shiu, Jiah-Shing, Ping-Chen [121]).

Dentro de las finanzas el problema de encontrar el portafolio que proporcione el mejor rendimiento al menor riesgo siempre está presente, debido a que se presentan numerosas alternativas de elección. Además, existen evidencias que sugieren que los mercados pueden ser ineficientes.

La construcción de portafolios óptimos puede ser muy complicada de lo que se piensa dado el vasto número de emisoras , de las diferentes posiciones que se puede tener da cada una de ellas y las diferencias que entre inversionistas y sus actitudes ante el riesgo.

La selección de portafolios se considera como un problema de optimización visto desde la óptica de Markowitz[79].

Además, para la construcción de portafolios siempre se ha considerado que la distribución de los rendimientos de cada emisora se distribuye normalmente, para efectos de pronósticos, cosa que no siempre se cumple. Esta es una justificación para la utilización de los AG's, ya que estos no necesitan de este supuesto para encontrar buenas soluciones dentro del gran espacio de búsqueda que representan la construcción de portafolios de inversión.

Otra buena justificación, radica en que los rendimientos de las emisoras son independientes, y el hecho de generar un portafolio hoy, independientemente del método utilizado, no garantiza que mañana dé los resultados que propuso. Dado lo anterior, los AG's son otra opción para la construcción de portafolios.

El propósito del presente trabajo es proponer un modelo de ayuda a la decisión para selección de portafolios de inversión basado en AGs. La justificación se sustenta en que en general el dominio de las decisiones financieras se encuentra acotado en el esquema de numerosas alternativas de elección, por lo que los AGs, comprendida como una técnica que permite emplearse en problemas con espacios de búsqueda muy grandes, provee una alternativa para encontrar buenas soluciones a este problema.

Como asistencia al AG se utilizó la teoría de PAC-Learning (Probably Approximately Correct Learning) para la estimación del tamaño de Población que utiliza el AG dentro del Modelo. Propuesto por Hernández, Buckles y Martínez [58].

Como funciones de aptitud para el diseño del portafolio se tienen: Primero, la Varianza (Var), la cual provee una medida del riesgo de los portafolios. La segunda se refiere a la relación Rendimiento/Var, explicado como un conjunto de acciones que evidencien mayor rendimiento con la menor Var, simultáneamente, y Tercero el rendimiento por si solo.

El documento está organizado de la siguiente manera:

- La primera sección se definen los objetivos del trabajo
- La segunda sección ofrece el marco teórico y una perspectiva general de la aplicación de los AGs en portafolios de inversión y en modelos de toma de decisiones.
- La tercera sección explica la metodología desarrollada para el diseño del modelo de ayuda a la decisión utilizando AGs, PAC learning para el tamaño de la población y el criterio de la Varianza
- La cuarta analiza los resultados . Mientras en una quinta se expone las conclusiones y recomendaciones del trabajo.
- Finalmente la último sección se describe el software de aplicación que se desarrolló como parte del modelo.

## 2. OBJETIVOS

- El objetivo del presente trabajo es el de tratar de resolver el problema de optimización de portafolios de Inversión con acciones utilizando Algoritmos Genéticos.
- Proponer un modelo para toma de decisión, para el caso de portafolios de Inversión en acciones.
- Implementar un software de aplicación que incluya el Algoritmo Genético, que dé las facilidades de ingresar los rendimientos de las emisoras y que permita al usuario modificar los parámetros que representen sus preferencias. Todo esto con el fin de generar la mejor información posible para que el usuario tome la mejor decisión en cuanto a selección de portafolios.
- Mostrar que éste modelo genera buenos resultados al compáralos con:
  1. Modelo de programación Lineal propuesto por Speranza [107] que simplifica el modelo de Markowitz [79].
  2. Índice de precios y cotizaciones de la Bolsa Mexicana de Valores
  3. Capital Asset Pricing Model..Para el rendimiento de tasa libre de riesgo se tomo la tasa de CETES a 28días, y para el rendimiento de mercado el rendimiento del Índice de Precios y Cotizaciones de la Bolsa Mexicana de Valores.



4. Combinación del modelo de Programación Lineal de Speranza y el Modelo propuesto, Se corrió el modelo de Programación lineal propuesto por Speranza, y los resultados de este se utilizaron como entrada para el modelo propuesto con AG.
5. Combinación del modelo Modelo propuesto y el de Programación Lineal de Speranza . Se corrió el modelo de AG propuesto y los resultados de este se utilizaron como entrada para el modelo Programación lineal. propuesto por Speranza.

## **3. Marco Teórico**

### **3.1 Algoritmos Genéticos**

En los últimos 30 años ha crecido el interés en sistemas de resolución de problemas basados en los principios de evolución y herencia. Dichos sistemas mantienen una población de soluciones potenciales, y tienen un proceso basado en la “adecuación” de cada una de estas soluciones , y algunos operadores “genéticos”. Un tipo de estos sistemas es una clase de Estrategias de Evolución, es decir, algoritmos que imitan los principios de evolución natural como problemas de optimización de parámetros.

Programación Evolutiva de Fogel es una técnica de búsqueda a través de un espacio de pequeñas máquinas de estado finito. Otro tipo de sistemas basados en evolución son los algoritmos genéticos de Holland (GAs) . En 1990, Koza propuso una evolución basada en sistemas de Programación genética, para búsqueda del programa de cómputo más adecuado para la solución de un problema particular.

El termino de Programas de Evolución o Evolutivos se usa para nombrar aquellos sistemas basados en evolución. La estructura general de un programa de evolución es el siguiente:

```

Procedure Programa de evolución
Begin
    t=0
    inicializa P(t)
    evalua P(t)
    While (not condicion de termino) do
    begin
        t=t+1
        selecciona P(t) de P(t-1)
        altera P(t)
        evalua P(t)
    end
end.

```

El programa de evolución es un algoritmo probabilístico que mantiene una población de individuos,  $P(t) = \{x'_1, \dots, x'_n\}$  para la iteración t, cada elemento representa una solución potencial para el problema planteado, y , en cualquier programa de evolución es implementada como alguna estructura de datos S (posiblemente compleja). Cada individuo  $x'_i$  es evaluada para obtener alguna medida de su “adecuación”. Entonces una nueva generación con una nueva población (iteración t+1) es formada por medio de la selección de individuos mas adecuados (paso Selecciona). Algunos miembros de la nueva generación sufren transformaciones (paso Altera) por medio de operadores “genéticos” para formar nuevas soluciones. Estas son transformaciones unitarias (tipo mutación). Las cuales crean nuevos individuos por medio de pequeños cambios en un solo individuo ( $m_i : S \rightarrow S$ ), y transformaciones de orden mayor  $C_i$  (tipo entrecruzamiento), el cual crea nuevos individuos por combinación de partes de varios (dos o mas) individuos ( $c_i : S \times \dots \times S \rightarrow S$ ). Después de algunas generaciones el programa converge. Se espera que esta sea la solución mas cercana al óptimo.

### **3.1.1 Que es un Algoritmo Genético.**

Existen una gran variedad de problemas de optimización, que no tiene un algoritmo de solución razonablemente rápido. Este tipo de problemas es posible atacarlo por medio de algoritmos eficientes los cuales nos permitan encontrar una solución muy cercana al óptimo. Además de poderse emplear en problemas cuyo espacio de búsqueda tiene explosión combinatoria.

Estos tipos de tareas se encargan de buscar soluciones en un espacio potencial de soluciones. Esta tarea es posible verla como un proceso de optimización. Para grandes espacios de búsqueda son usadas técnicas de inteligencia artificial.. Los Algoritmos genéticos es una de estas técnicas: estos son algoritmos estocásticos que utilizan operaciones que aparecen en estudios de fenómenos naturales en biología: herencia genética y la lucha por la supervivencia Darwiniana.

“La idea tras los algoritmos Genéticos es la evolución natural. En la evolución, el problema que cada especie enfrenta es el de buscar adaptaciones benéficas a un ambiente cambiante y complicado. El “conocimiento” que cada especie a ganado es incorporado en la estructura de los cromosomas de sus miembros”. Es decir se realizan cambios que se manifiestan en representaciones estructurales y funcionales y, en representaciones internas de conocimiento.

Por ejemplo: Los Conejos.

En un tiempo dado existió una población de conejos, algunos de ellos eran mas veloces e inteligentes que otros. Estos conejos rápidos e inteligentes son menos propensos a ser comidos por los lobos y por lo tanto mas de estos conejos sobreviven y se reproducen. Algunos de los conejos lentos sobreviven solo por suerte. Esta población se reproduce y se cruza entre sí: lentos con rápidos, rápidos con rápidos , inteligentes con tontos, etc. De estos algún material genético es mutado, y como resultado los conejitos serán (en promedio) mas rápidos e inteligentes que los de la población original ya que los padres que sobrevivieron a los lobos fueron mas rápidos e inteligentes.

“El principio fundamental de selección como el principio fundamental de evolución fue formulando por C. Darwin mucho antes del descubrimiento de los mecanismos genéticos.

En 1865 G. Mendel descubrió los principios básicos de la transferencia de factores hereditarios.”

“En 1900 las leyes descubiertas por Mendel fueron re-descubiertas por Vries, Correns and Tschermak. La genética fue ampliamente desarrollada por T. Morgan y sus colaboradores. Estos últimos probaron que los cromosomas son los que transmiten la información hereditaria. Y que los genes, representan la información hereditaria, están alineados en los cromosomas.

Sin embargo, a pesar de que aparentemente estas dos teorías se oponen, en los 20's (Cetverikov) prueba que las genética de Mendel y la teoría de la selección natural de Darwin no se encuentran en conflicto sino que se unen para crear la teoría moderna de la evolución.”

El vocabulario empleado por los Algoritmos Genéticos es el mismo que la genética natural:

Se habla sobre individuos (ó genotipos, estructuras) en una población. Frecuentemente estos individuos son llamados también cadenas o cromosomas. Cada célula de todo organismo de una especie dada tiene un cierto número de cromosomas (el hombre tiene 46), sin embargo por lo general se habla de un cromosoma como individuo. Los cromosomas están constituidos por unidades -genes arreglados en sucesión lineal. Cada gen controla la herencia de ciertas características. Genes de ciertos caracteres están colocados en ciertas partes de los cromosomas que son llamados locus (posición de la cadena). Cada carácter de los individuos ( como color de cabello) puede manifestarse el mismo de diferente manera; el gene se dice que está en varios estados, llamados alelos (valores distintivos).

Cada genotipo (un solo cromosoma) podría representar una solución potencial a un problema ( el significado de un cromosoma en particular, es decir, su fenotipo es definido externamente por el usuario). Un proceso de evolución se efectúa en una población de cromosomas que corresponde a un espacio de soluciones potenciales. Cada búsqueda requiere balancear dos objetivos (aparentemente en conflicto) : explotar las mejores soluciones y explorar el espacio de soluciones.

Los AGs son una clase especial de métodos de búsqueda general que obtienen un buen balance entre explotación y exploración del espacio de búsqueda.

Los AGs han tenido mucho éxito en aplicaciones a problemas de optimización como ruta de cableado (wire routing), programación (scheduling) control adaptativo (adaptative control), jugar juegos (game playing), modulación cognitiva, problemas de transporte, problemas tipo agente viajero, problemas de control óptimo. Optimización de consultas en bases de datos, etc.

Otras aplicaciones dentro de la inteligencia artificial son: reconocimiento de patrones, categorización y asociación,

Actualmente muchos problemas de optimización pueden solo ser resueltos por aproximación, debido a que para poder encontrar la solución óptima sus soluciones involucran una cantidad enorme de cálculos. A este tipo de problemas se los conoce como NP-Complejos o NP-Duros. El principal factor que limita la aplicación de los AGs, es el poder de cómputo. Los AGs pertenecen a la clase de algoritmos probabilísticos y son muy diferentes de los algoritmos al azar ya que combinan elementos de búsqueda directa y estocástica. Debido a esto los AGs son mas robustos que los métodos existentes de búsqueda directa. Otra propiedad de estos algoritmos basados en operadores genéticos es que se mantiene una población de soluciones potenciales; otros métodos solo procesan un solo punto del espacio de búsqueda.

Por ejemplo los métodos de Hillclimbing (escalar la cima) solo proveen valores de un óptimo local y estos valores dependen del punto que se seleccionó como inicial, es decir, pueden quedar atrapados en máximos o mínimos locales. Una variante de este método es seleccionar varios puntos iniciales que no deben ser seleccionados al azar, ya que el

resultado del siguiente punto dependerá del anterior. El algoritmo termina cuando ya no es posible obtener mejora en el valor de la función objetivo.

La técnica del recocido simulado elimina la mayoría de las desventajas de los métodos de escalamiento de la cima: la solución no depende del punto de inicio y terminan cerca del punto óptimo. Este es alcanzado introduciendo una probabilidad  $p$  de aceptación (es decir, reemplazo del punto actual por el punto nuevo):  $p=1$  si el nuevo punto mejora el valor de la función objetivo;  $p>0$  de otra forma. En este último caso, la probabilidad de aceptar  $p$  está en función de los valores de la función objetivo del punto actual y el punto nuevo, y un parámetro de control adicional llamado “temperatura”,  $T$ . En general a menor temperatura menor probabilidad de aceptar un punto nuevo, Durante la ejecución del algoritmo la temperatura  $T$  es disminuida en pasos. El algoritmo termina cuando el valor de  $T$  es tan pequeño que no se aceptan más cambios.

Como se mencionó antes los AGs realizan una búsqueda multidireccional manteniendo el espacio de soluciones potenciales y promueve la formación de información e intercambio entre estas direcciones. La población sufre una evolución simulada: cada población de soluciones relativamente buenas se reproduce, mientras que las que son relativamente malas mueren. Para distinguir entre las diferentes soluciones se utiliza una función de aptitud (evaluación) que juega el rol de ambiente.

Un AGs para un problema en particular tiene los siguientes componentes:

- una representación genética para soluciones potenciales del problema.
- una forma de crear una población inicial de soluciones potenciales.



- una función de evaluación que juega el rol de ambiente, valorando soluciones en términos de “adecuación”,
- los operadores genéticos alteran la composición de los hijos,
- valores de varios parámetros que el algoritmo genético utiliza (tamaño de la población, probabilidades de aplicar los operadores genéticos).

Una definición de Algoritmo Genético dada por Forrest [46] es: “un procedimiento interactivo que mantiene la población de estructuras que son soluciones candidatas a un dominio específico de desafíos. En cada incremento temporal (llamado generación), las estructuras en la generación actual son clasificados por su efectividad como dominio de soluciones, y con base a estas evoluciones, una población nueva de candidatos es formada usando “operadores” genéticos específicos, los cuales son: reproducción, cruzamiento y mutación”.

### **3.1.2 Supuestos para su modelación:**

- -El ambiente y sus entradas y salidas puede ser representadas como cadenas de símbolos de una longitud fija basado en un alfabeto dado. Este alfabeto es regularmente dado como  $\{0,1\}$  (Se ha encontrado evidencia que el alfabeto binario es óptimo [52]).
- -Cada punto en el espacio del problema puede ser considerado como un individuo representado únicamente dentro del sistema por una cadena generada del alfabeto del ambiente. Esta cadena funciona como “material genético” que especifica posiciones (locus) en la cadena

(cromosoma) conteniendo símbolos únicos (genes) tomados en valores (alelos).

- En cualquier instante en el tiempo, el sistema mantiene una población  $P(t)$  de cadena (también llamados clasificadores) que representan el conjunto actual de soluciones del problema. El proceso comienza con una generación al azar o diseñando un especificación de la población inicial.
- -La única retroalimentación disponible para una estrategia adaptativa es el valor de la medida del desempeño (adecuación). Esta retroalimentación es usualmente llamada retroalimentación de “orden-cero”; la ultima información que es demandada para adaptaciones es una indicación de como se a llevando a cabo un proceso de buena adaptación.
- -La medida del tiempo se mide en intervalos discretos llamados generaciones.
- La información *no a priori* involucrando al espacio del problema es requerida para una estrategia adaptativa , aunque esta restricción puede ser relajada.

Ciclo de ejecución:

1. Del conjunto de soluciones existentes, se seleccionan candidatos de acuerdo a la adecuación para la reproducción. Los candidatos con el mayor factor de adecuación tienen una gran probabilidad de contribuir a la descendencia.

2. Después de la reproducción, al azar se seleccionan pares para el cruzamiento (intercambio de material genético entre dos candidatos) y se selecciona de nuevo al azar, un lugar donde el material será intercambiado, como resultado se tendrá la creación de descendencia.
3. Aplicar el operador genético secundario: Mutación.
4. Evaluar el desempeño de la población nueva.
5. Eliminar los actores débiles. Iterar el proceso.

Una medida debe ser introducida para asegurar que el espacio del problema es abarcado comprensiblemente. La variación de la población es desarrollada por los operadores genéticos.

### **3.1.3 Operadores Genéticos:**

**Reproducción:** La población inicial  $P(0)$  puede ser seleccionada heurísticamente o al azar. Las estructuras de la próxima generación son escogidas de miembros de generaciones anteriores por medio de un proceso de selección probabilístico. Que asegura que el número de veces esperado a que una estructura sea seleccionada es aproximadamente proporcional al desempeño de la estructura relativo al resto de la población. Estructuras con alto grado de adecuación tendrán una gran probabilidad de contribuir a la descendencia.

**Cruzamiento:** Las estructuras son representadas por cadenas de símbolos. Si los símbolos son binarios, el cruzamiento puede ser implementado seleccionando una posición dentro de la cadena al azar (llamado punto de entrecruzamiento) e intercambiar los segmentos de la derecha o izquierda de éste punto con otra cadena particionada

similarmente. El cruzamiento provee nuevos puntos para probar dentro del espacio del problema, cada evaluación de la cadena de longitud  $L$  agrega conocimiento sobre el desempeño de los  $n^L$  hiperplanos representados por la estructura, donde  $n$  es el número de símbolos únicos en el alfabeto. Los AGs derivan su poder del uso de mecanismos simples y selectivos para explotar eficientemente este enorme aumento de conocimiento acumulado.

**Mutación:** La Mutación crea nuevos individuos modificando uno o varios valores de los genes de un individuo existente. La mutación no es un operador genético primario. En sistemas biológicos, la probabilidad de una mutación genética es baja, al igual que en estos modelos. La Mutación asegura que la probabilidad de búsqueda de una región en el espacio de problemas nunca es cero, y por medio de la selección y eliminación prevé la pérdida completa de material genético. Los AGs son extremadamente flexibles, sus entradas y salidas pueden representar una gran variedad de fenómenos. Incluyendo problemas de optimización combinatoria, procesamiento de imágenes, control en sistemas de tuberías y aprendizaje de máquinas.

#### **3.1.4 Parámetros Genéticos:**

K.A. de Jong representó los sistemas adaptativos como una retroalimentación estándar de estructuras de control. Este enfoque tiene dos ventajas: El gran cuerpo de la teoría clásica puede ser enfocado de inmediato en el problema y, tiene una representación de adaptación formal relativamente fácil. Los formalismos pueden expresarse en los siguientes parámetros:

**Tamaño de la población:** ( $N$ ) El tamaño de la población afecta a la eficiencia global y la del AG. El AG en poblaciones pequeñas no provee un buen desempeño debido a que da una cobertura insuficiente del espacio del problema. Una población grande es mejor ya que representa a todo el problema en general y además prevé una convergencia prematura hacia soluciones locales en lugar de las globales.

**Tasa de cruzamiento:** ( $C'$ ) La frecuencia con la que el operador de cruzamiento es aplicado esta dado por la tasa de cruzamientos. Si la tasa de entrecruza es muy alta, las estructuras que presentan buen desempeño serán retiradas rápidamente antes de que puedan proveer mejoras, mientras que con una tasa baja de cruzamiento puede estancar la búsqueda ya que no permite que las estructuras evolucionen.

**Tasa de Mutación:** ( $M'$ ) Para incrementar la variabilidad de la población, se usa un operador secundario de búsqueda: el operador de mutación. La operación de mutación se aplica aleatoriamente. Cada unidad fundamental (bit, posición) en una estructura tiene una probabilidad finita de cambio. Una mutación de bajo nivel evita que una posición dada se congele como un simple valor. Una tasa alta de mutación resulta en esencia en una búsqueda al azar. Aproximadamente  $Mr*N*L$  mutaciones ocurren por generación, donde  $L$  es la longitud de la estructura.

**Diversidad Genética:** ( $G$ ) La Diversidad Genética controla el porcentaje de la población a ser reemplazado durante cada generación.  $N*G$  estructuras de la población  $P(t)$  son seleccionadas para ser reemplazadas en  $P(t+1)$ . Un valor de  $G=1.0$  significa que la población total es reemplazada cada generación.

**Estrategia de selección:** (S) Variadas estrategias de selección son posibles: Se consideran dos de estas. La primera es la estrategia pura en donde cada estructura de la población actual es reproducida en proporción a las estructuras adecuadas. La segunda de estas, es una estrategia elitista : la selección pura es realizada primero y las estructuras con el mejor desempeño son seleccionadas para sobrevivir a la siguiente generación. Evitando la remoción por cruzamiento, mutación o error de muestra.

**Factor de escalamiento:** (SF) Mantener la diversidad de la población durante la evolución es importante. Un individuo superdotado que domina la población hasta que no sea posible un mejoramiento futuro puede aparecer tempranamente en el proceso. Este altiplano genético puede ser evadido de tal manera que el espacio del problema sea suficientemente explorado. Desempeños similares pueden aparecer tardíamente en el ciclo de vida del sistema: estos deben ser colocados y su desempeño respectivo pesado para que refleje su “adecuación” relativa.

**Convergencia:** Si el AG ha sido correctamente implementado, la población evolucionará a lo largo de generaciones sucesivas de forma que la adaptación del mejor y del promedio general se aproximarán hacia el óptimo global. La convergencia es la progresión hacia la uniformidad. Un gen ha convergido cuando el 95% de la población tiene el mismo valor. La población converge cuando todos los genes de cada individuo lo hacen.

### **3.1.5 Aplicaciones:**

Proceso de control dinámico.

Inducción y optimización de reglas.

Optimización paramétrica de elementos mecánicos.

Optimización de arquitectura de redes neuronales.  
Coloración de mapas.  
Problemas de asignación de recursos.  
Descubrimiento de nuevas topologías de conectividad.  
Simulación de modelos biológicos de comportamiento y evolución.  
Predicción econométrica en mercado de valores.  
Sistemas de ayuda a la decisión.

### **3.2 Algoritmos Genéticos en portafolios de Inversión**

Métodos y técnicas usados en otras áreas se han aplicado para solucionar problemas financieros con el fin de obtener más alternativas de solución. Uno de estos métodos son los Algoritmos Genéticos.

Dentro de las finanzas el problema de encontrar el portafolio que proporcione el mejor rendimiento al menor riesgo siempre está presente. Dicho problema ha sido atacado con Algoritmos Genéticos

En 1998 Bao y Wong [9] proponen un modelo teórico híbrido de portafolio basado en AGs y Quantización Vectorial que fue aplicado a Jardine Fleming Asean Unit Trust price predication. En este modelo se aplicaron AGs , lógica difusa y el método de compresión de quantización vectorial para la predicción del desempeño de portafolios de inversión.

Shoaf y Foster [105] realizan la comparación entre la programación cuadrática y el modelo de Markowitz modelado con AGs, para un portafolio eficiente, como resultado se obtienen mejoras en cuanto a resultados y tiempo de ejecución con el AG sobre la programación cuadrática.

En 2000 Fukanga [49] Plantea un portafolio basado en AGs donde los recursos computacionales son seleccionados de diferentes conjuntos de parámetros de control. Identifica el conjunto de parámetros de control mas útiles que den como resultado la selección de los recursos de cómputo idóneos que generen un algoritmo para un portafolio de inversión basado en AGs.

En [92] Orito y Yamazaki utilizan la correlación como un parámetro para la selección de un buen portafolio utilizando AGs aplicado a Tokio stock Exchange Prices Indexes (TOPIX) obteniendo resultados útiles.

En [124] Wen-Shiu et al. proponen un modelo para selección de portafolios usando algoritmos genéticos utilizando como función de aptitud una combinación de índices de mercado y requerimientos del usuario.

En [7] Baba construye un sistema inteligente de ayuda a las decisiones utilizando Redes Neuronales y los AGs para negociar en Tokio stock Exchange Prices Indexes (TOPIX)



### **3.3 Aprendizaje Probablemente aproximadamente Correcto (Probably Approximately Correct Learning- PAC Learning.)**

En las últimas décadas la mayoría de los trabajos en aprendizaje de máquina han sido divididos en tres áreas principalmente: reconocimiento de patrones (Duda and Hart [34]), ciencia cognitiva de Aprendizaje máquina (Michalski, Carbonell y Mitchel [86]), y teoría de la inferencia inductiva (Angluin ,and Smith [3]). A pesar de que cada uno de estas áreas tiene sus propias metas y ha desarrollado sus propias metodologías y terminologías, Valiant [123] introdujo un nuevo enfoque de aprendizaje de máquina, que incorpora elementos de cada una de estas áreas y da la posibilidad de una mezcla de enfoques a futuro.

El enfoque de Valiant difiere de otros enfoques de Inteligencia Artificial (IA) de aprendizaje por ejemplos en que este no requiere que la hipótesis producida por el algoritmo de aprendizaje sea exactamente correcta , solo debe tener una alta probabilidad de ser aproximadamente correcta.

Esto quiere decir, un algoritmo de aprendizaje exitoso se define como un algoritmo que, dado un número suficiente de ejemplos al azar de un objetivo desconocido , produce con una alta probabilidad, una hipótesis que es una buena aproximación del concepto objetivo. Su desempeño se mide en términos del número de ejemplos necesarios y del poder de cómputo requerido para producir la hipótesis.

El punto principal de Valiant radica en que, al menos en principio, éste permite dar un análisis cuantitativo significativo del desempeño de los algoritmos de aprendizaje simbólicos de IA, similar a los análisis rigurosos

dados por algunos de los métodos numéricos de reconocimiento de patrones. Más aún, mientras este análisis está basado en teoría de probabilidad, y consecuentemente requiere de ciertos supuestos probabilísticos sobre la forma en que los ejemplos son generados y la forma en que el aprendizaje exitoso es definido, el modelo no necesita distribución alguna- lo que significa que los resultados pueden ser acogidos por cualquier distribución de probabilidad que soporte los ejemplos generados. Por lo tanto, es de esperarse que las cotas de desempeño derivadas de esta teoría funcionen en una amplia variedad de situaciones de aprendizaje reales.

### 3.3.1 Principios

PAC-Learnig o Aprendizaje aproximadamente correcto es una teoría del concepto de aprendizaje por ejemplos. Se supone un espacio  $X \in \mathfrak{R}$ . Un concepto Clase  $C \subseteq X$  es el conjunto de de posibles particiones de  $X$ ; el espacio Hipótesis  $H$  es definido de la misma manera y puede o no ser igual que  $C$ ; el concepto objetivo  $c \in C$  es una partición específica de  $X$ . Dado un número finito de ejemplos de un concepto objetivo  $c$ , la meta (de la máquina de aprendizaje) es el de encontrar la hipótesis  $h \in H$  la cual es una buena aproximación a  $c$ , con una alta probabilidad ( con alta probabilidad  $h$  sigue muy cerca el comportamiento de  $c$  ). La “buena aproximación ” de  $h$  a  $c$  debe ser medida por alguna métrica ( o al menos una pseudo métrica ) que estime el error  $\epsilon$  o la diferencia simétrica entre la hipótesis y el concepto objetivo. La “alta probabilidad” es indicada por el parámetro de confianza  $\delta$ . Formalmente, para un  $\epsilon$  y  $\delta$  pequeños la hipótesis  $h$  satisface

$$P_{\mu}(\text{Error}(h,c) > \epsilon) \leq \delta$$

Para cualquier concepto objetivo  $c$  y cualquier distribución de probabilidad  $P_{\mu}$ . El mínimo número de muestras necesario para alcanzar esa meta es llamado complejidad de la muestra.

Blumer citado por Hernández, A. Buckles, B., Martínez, A [58](ilustra lo siguiente:

Se desea aprender el concepto de “construcción regular o mediana” de un conjunto de ejemplos tomados del espacio  $X \in \mathbb{R}^2$ . Cada muestra  $x=[x_1,x_2] \in X$  es un vector cuyo primer elemento representa el peso y el segundo la altura. Se supone que el concepto “construcción regular o mediana” es el área limitada por las alturas  $h_{\max}$  y  $h_{\min}$ , y los pesos  $w_{\max}$  y  $w_{\min}$ , como se muestra en la fig. 3.1

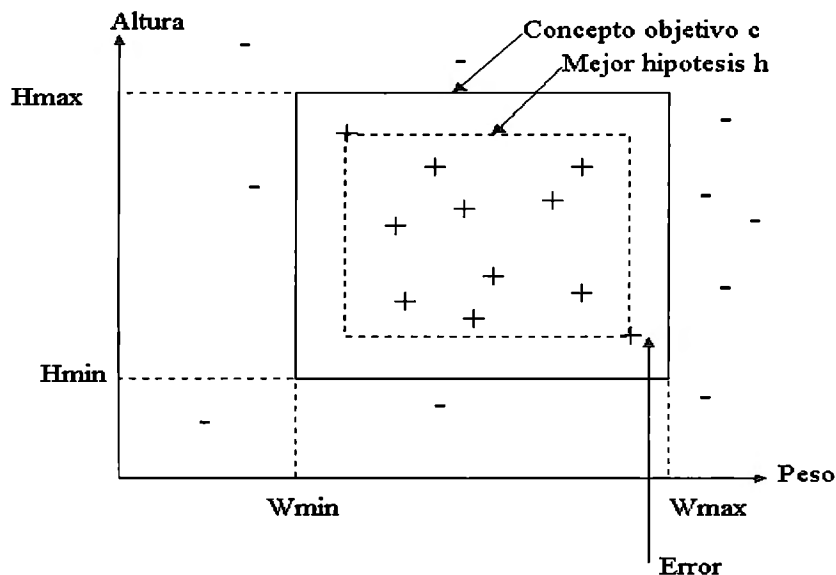


Fig. 3.1 Aprender el concepto de “construcción regular o mediana”

Un conjunto de ejemplos es trazado del espacio  $X$  y son clasificados por un *oráculo* en positivos (+) o negativos (-). La mejor hipótesis es el mayor cuadrado que encierra ejemplos positivos. Es posible ver fácilmente que conjunto de ejemplos grandes pueden derivar mejor la hipótesis, o sea la hipótesis mas cercana al concepto objetivo.

### 3.3.2 Complejidad de la muestra

A partir de aquí se deriva la complejidad de la muestra para espacios de hipótesis finitos. Se puede observar que existe una pequeña posibilidad de que la muestra caiga en el área del error, es decir la probabilidad de no error se expresa como  $(1-\epsilon)$ . Ahora, si se prueban  $m$  ejemplos la probabilidad de error se convierte en  $(1-\epsilon)^m$ . Se asume que el espacio de hipótesis es finito, entonces la probabilidad de error de la hipótesis es acotada en su limite superior por  $|H| \cdot (1-\epsilon)^m$  ( $|H|$  es la cardinalidad de  $H$ ).

Asegurando su probabilidad con  $\delta$  se tiene:

$$|H| \cdot (1-\epsilon)^m < \delta$$

aplicando la desigualdad  $(1-\epsilon)^m < e^{-\epsilon m}$  :

$$|H| \cdot e^{-\epsilon m} < \delta$$

Aplicando logaritmos

$$\ln |H| \cdot \ln e^{-\epsilon m} < \ln \delta$$

$$-\epsilon m < \ln \delta / |H|$$

Consecuentemente el número de ejemplos que aseguran la probabilidad de error de clasificación por  $\delta$  es:

$$m > 1/\epsilon(\ln|H| + \ln(1/\delta))$$

con esa complejidad de la muestra se garantiza

$$P_{\mu}(\text{Error}(h,c) > \epsilon) > 1 - \delta$$

Se asegura para cualquier nueva muestra con la misma probabilidad de distribución. Esta es la ecuación principal de PAC-Learning.

### 3.3.3 PAC – Tamaño de Población (Population Size)

Para el cálculo del tamaño de población se utiliza el concepto de distancia de Hamming que se define como: la cantidad de posiciones de BIT en la que difieren dos cadenas código, es decir que si dos palabras código están separadas una distancia de Hamming  $d$ , se requerirán  $d$  errores de 1 BIT para convertir una en otra (Hamming 1950 citado por Tanenbaum [115])

Modificando la longitud

$$m > 1/\epsilon(\ln|H| + \ln(1/\delta))$$

para estimar el tamaño inicial de población para un Algoritmo Genético (AG) que con probabilidad de  $1 - \delta$  contenga al menos un individuo con distancia de Hamming  $d$ . Supóngase que la longitud de cadenas binarias es igual a 20,  $l=20$ . De esta ecuación es necesario determinar  $H$  y  $\delta$ . El nivel de confianza  $\delta$  es fijado por el usuario y no depende del dominio del problema. El tamaño de espacio de la hipótesis de los cromosomas se derivada como en el punto anterior (complejidad de la muestra).

El número de hipótesis representables por las cadenas de longitud  $l$  es

$$|H| = 2^l$$

Sustituyendo en la ecuación  $m > 1/\varepsilon(\ln|H| + \ln(1/\delta))$  y usando logaritmos la complejidad de la muestra es:

$$m > 1/\varepsilon(\ln 2 + \ln(1/\delta))$$

Para el caso GA el error se debe interpretar como el error  $\varepsilon$  que existe alguna distancia de Hamming  $d$  dada. El error asociado con una distancia de Hamming  $d=0$ , es la probabilidad que  $\binom{20}{0}$  de las  $2^{20}$  hipótesis, concuerden con el cromosoma objetivo. Es decir:

$$\varepsilon(d=0) = \frac{\binom{20}{0}}{2^{20}}$$

$$\varepsilon(d=1) = \frac{\binom{20}{0}}{2^{20}} + \frac{\binom{20}{1}}{2^{20}}$$

De esta manera el error asociado con la distancia de Hamming de 1  $\varepsilon(1)$  es la probabilidad de que una de  $\binom{20}{0} + \binom{20}{1}$  hipótesis concuerde con el cromosoma objetivo. Formalmente, para cadenas binarias de longitud  $l$  y distancia de Hamming  $d$ ,

$$\varepsilon(d) = \frac{\sum_{i=1}^d \binom{l}{i}}{2^l}$$

es la cantidad de error inherente a la distancia de Hamming,

### 3.4 Portafolios De Inversión.

La historia contemporánea de la teoría de portafolio da comienzo con el trabajo de Harry Markowitz [79], quien después recibiera el premio novel

en economía. En 1952 Markowitz demostró como crear una frontera para portafolios óptimos (o “eficientes”), teniendo el mayor rendimiento dado un nivel de riesgo, que es medido por la desviación estándar de los rendimientos del portafolio. Sin embargo esta aplicación tenía grandes restricciones dado el poder computacional de la época.

Sin embargo en 1963, William Sharpe (quien también obtuvo el premio Nóbel) desarrolló una versión simplificada del modelo de su mentor Markowitz, que no tenía tantos requerimientos de cómputo. Se basaba en una fórmula que aproximaba la varianza del rendimiento del portafolio, esta se conoce como el modelo del índice simple.

En 1960, varios economistas financieros investigaron la influencia del modelo de Markowitz en la valuación de “securities”. Esta investigación se centró en el impacto de la formación del portafolio sin que existiese una fricción del mercado. El resultado de la investigación se conoce hoy en día como Capital Asset Pricing Model (CAPM), desarrollado independientemente por William Sharpe [103], Jan Mossin [88], John Lintner [77]. Este modelo demuestra que el equilibrio del rendimiento de una acción es una función lineal de su riesgo sistemático. El CAPM es ampliamente usado a pesar del debate que existe sobre su validez.

A mediados de la década de los 60's Eugene Fama dió una definición elegante de la eficiencia de los mercados: si la información es rápida y eficientemente digerida por los analistas de mercados, es imposible generar rendimientos anormales por medio de alguna forma de análisis. Además, si los eventos informativos ocurren de forma aleatoria, los precios de las acciones deben moverse aleatoriamente de acuerdo al análisis técnico dado.

### 3.4.1 Definición: Portafolio de inversión

Un portafolio se define como la asignación de proporciones establecidas de activos con respecto a un monto dado de capital, es decir constituye el criterio de conformación de las partes constituyentes, así como sus dimensiones cuantitativas, de los bonos, acciones, obligaciones u otras reservas de valor que forman el proyecto de inversión bursátil. La naturaleza y definición del portafolio están asociados a parámetros básicos en la toma de decisiones como es el rendimiento y el riesgo. En general, un agente racional desea maximizar el primero y minimizar el segundo, en el mejor de los escenarios (Del Valle [29]).

El rendimiento del portafolio es el resultado de la suma ponderada del rendimiento promedio de cada una de las acciones que están incluidas en el portafolio. Para este caso en particular y como un supuesto, nuestro inversionista elige una participación uniforme y constante de los activos que desea incorporar. Dentro de este modelo el rendimiento se calculó de la siguiente forma:

$$R = \sum_i w_i r_i$$

donde:

R : Rendimiento del portafolio.

$w_i$ : Ponderación sobre el activo

$r_i$ : Promedio de rendimiento de la activo i



### 3.4.2 Varianza del portafolio :

La varianza del portafolio se define como:

$$\sigma_p^2 = w' \Sigma w$$

donde:

$W$  : Vector de ponderaciones de cada emisora del portafolio

$\Sigma$  : Matriz de Varianzas y Covarianzas de los rendimientos de las emisoras del portafolio.

La varianza de un portafolio nos indica el riesgo del mismo, uno de los indicadores de riesgo más utilizados actual mente y que hacen uso de la varianza en portafolios de inversión es el Valor al Riesgo (VaR).

Actualmente la mayoría de los bancos , corredurías y fondos mutualistas usan métodos similares para medir su exposición al mercado. En los Estados Unidos agencias como Moody's and Estándar Poor's (S&P), Los estándares de la contabilidad financiera, (Financial Accounting Standards Board), y la comisión de intercambio de acciones (Securities and Exchange Comission) utilizan el Var. (Jorion ,1997 ).

El VaR resume la máxima pérdida esperada ( o peor pérdida) sobre una horizonte objetivo con un intervalo de confianza dado.

### 3.4.3 Diversificación y riesgo de un portafolio

Para explicar la relación entre la varianza del portafolio y el número de emisoras que intervienen en un portafolio se toma en primer lugar la varianza de un portafolio con N emisoras:

$$\sigma_p^2 = \sum_{i=1}^N \sum_{j=1}^N w_i w_j COV (r_i r_j)$$

donde:

- w<sub>i</sub>: ponderación de la emisora i
- w<sub>j</sub>: ponderación de la emisora j
- r<sub>i</sub>: rendimiento de la emisora i
- r<sub>j</sub>: rendimiento de la emisora j

Esta ecuación se puede reescribir como:

$$\sigma_p^2 = \sum_{i=1}^N \sigma_i^2 w_i^2 \sum_{\substack{j=1 \\ i \neq j}}^N w_j COV (r_i r_j)$$

Si se supone que todas las emisoras que integran el portafolio tienen la misma ponderación, entonces la ponderación para cualquier emisora es de 1/N, dado esto la ecuación anterior se puede reescribir como:

$$\sigma_p^2 = \sum_{i=1}^N (1/N) \sigma_i^2 \sum_{\substack{j=1 \\ i \neq j}}^N (1/N)^2 COV (r_i r_j)$$

Existen N términos de varianza y N(N-1) términos de covarianza.

Factorizando se obtiene:

$$\sigma_p^2 = (1/N) \sum_{i=1}^N (\sigma_i^2 / N) + (N - 1/N) \sum_{\substack{j=1 \\ i \neq j}}^N COV (r_i r_j) / N(N - 1)$$

La sumatoria de varianzas de cada emisora  $i$  dividido entre el número de emisoras es igual a la media de la varianza. La sumatoria de las covarianzas divididos entre  $N(N-1)$  es igual a la media de la covarianza.

Al sustituir las sumatorias con las medias se obtiene la ecuación:

$$\sigma_p^2 = (1/N) \overline{\sigma_i^2} + (N-1/N) \overline{COV(r_i, r_j)}$$

Donde:

$\overline{\sigma_i^2}$ : Varianza Promedio

$\overline{COV(r_i, r_j)}$ : Media de Covarianza

Esta última ecuación muestra el efecto de diversificación en el riesgo del un portafolio. El primer supuesto es el de que todo el riesgo es específico de cada emisora, lo que implica que la covarianza entre rendimientos de emisoras sea 0. Para este caso la varianza del portafolio es igual a  $1/N$  multiplicada por la varianza promedio de las emisoras que lo componen. Ya que la varianza del portafolio se acerca a 0 a medida que el número de emisoras que componen el portafolio se incrementa, el riesgo puede ser eliminado generando portafolios con gran número de emisoras si la covarianza entre emisoras es igual a 0.

### 3.4.4 Modelo de Markowitz

Este modelo es el mas aceptado a nivel mundial, el modelo básico se representa como el problema de optimización:

Minimizar  $X$

Equivalente  $V_p = \sum_{i=1}^n \sum_{j=1}^n \sigma_{ij} x_i x_j$

Sujeto a

$$V_p = \sum_{i=1}^n \sigma_i^2 x_i^2 + \sum_{i=1}^n \sum_{j=1}^n \sigma_{ij} x_i x_j$$

$$\sum_{i=1}^n R_i^2 x_i^2 = R_p$$

$$\sum_{i=1}^n x_i^2 = 1$$

$$x_i \geq 0, \quad i = 1, \dots, n$$

Donde

$n_i$  número de emisoras disponibles

$x_i$  es la proporción de la emisora  $i$  en el portafolio

$R_i$  valor esperado de rendimiento de la emisora  $i$

$R_p$  valor del rendimiento esperado en el portafolio

$\sigma_i^2$  es la varianza de los rendimientos de la emisora  $i$

$\sigma_{ij}$  es la covarianza de los rendimientos de las emisoras  $i$  e  $j$

$V_p$  Varianza del rendimiento del portafolio

### 3.4.5 Modelo Speranza

El modelo de Speranza [107]:

$$\begin{aligned} & \text{Minimizar} \quad \frac{\sum_{t=1}^T y_t}{T} \\ & y_t + \sum_{j \in J} (r_{jt} - r_j) x_j \geq 0 \quad t = 1, \dots, T \\ & \sum_{j \in J} r_j x_j \geq \rho C \\ & \sum_{j \in J} x_j = C \\ & 0 \leq x_j \leq u_j \quad j \in J \\ & y_t \geq 0 \quad t = 1, \dots, T \end{aligned}$$

donde:

$X_i$  : proporción de la emisora  $i$  en el portafolio  $X = [x_1, x_2, \dots, x_n]$

$r_j$  : media del rendimiento del activo  $j$

$r_{jt}$  : rendimiento del activo  $j$  en el tiempo  $t$

$\rho$  : rendimiento esperado del portafolio

$C$  : Inversión total

$y$  : Variables Auxiliares que hacen posible el cambio de programación no-lineal a lineal

Este modelo es simple y eficiente debido al número de variables que maneja.

El propósito de este modelo es el de demostrar que la optimización de portafolio usando el modelo “Mean absolute deviation Risk ( $L_1$  risk model)” puede simplificar las dificultades presentadas por el modelo clásico de Markowitz.

En particular éste tipo de modelo se puede resolver por programación lineal y no cuadrática, reduciendo el tiempo de cálculo.

### 3.4.6 Capital Asset Pricing Model (CAPM)

Este Modelo describe la relación entre el rendimiento esperado de una acción y su riesgo bajo condiciones de equilibrio de mercado en un mercado de capital en donde los inversionistas hacen su selección de portafolios con el modelo de media varianza de Markowitz.

Capital Asset Pricing Model

$$E(r_i) = r_f + [E(r_M) - r_f] \frac{\text{Cov}(r_i, r_m)}{\sigma_M^2}$$

Donde

$r_i$  : rendimiento de la emisora  $i$

$r_f$  : rendimiento de la tasa libre de riesgo

$r_M$  : rendimiento del mercado

Nota:

Para el rendimiento de tasa libre de riesgo se tomó la tasa de CETES a 28 días, y para el rendimiento de mercado el rendimiento del Índice de Precios y Cotizaciones de la Bolsa Mexicana de Valores.

## **4. METODOLOGÍA**

### **4.1 Modelación del portafolio con Algoritmos Genéticos**

#### **4.1.1 El Algoritmo Genético**

El Algoritmo Genético que se utilizó en este modelo fue el basado en el propuesto por Goldberg [52], su funcionamiento fue optimizado para reducir tiempos de ejecución en la computadora y así obtener resultados en el menor tiempo posible.

El algoritmo original del Golberg se modificó en la parte del mecanismo de selección debido a que los valores de la función de aptitud pueden ser positivos y negativos. Esto puede influir ya que si se desea maximizar con valores de la función de aptitud negativos es necesario generar las proporciones dentro del mecanismo de selección aplicando el valor absoluto a la función de aptitud.

Además, para las situaciones en las que se buscaba minimizar las funciones de aptitud y el AG maximizaba, se modificó el mecanismo de selección calculando las proporciones con los inversos de los valores de la función de aptitud, de tal forma que los valores más pequeños tuvieran más proporción en el mecanismo de selección, y así el AG se dirigiera hacia la dirección deseada.

#### 4.1.2 Codificación del portafolio con AGs

Para la codificación del portafolio se utiliza una cadena de ceros y unos, esta cadena es el cromosoma dentro del AG. Éste cromosoma representa a todo el conjunto de emisoras que se analizan. Es decir, el AG genera cadenas de ceros y unos con un tamaño igual al número de emisoras que serán elegibles para generar el portafolio (Ingresadas por el usuario). Las posiciones de la cadena son mapeadas con los nombres de las emisoras. Por ejemplo (Fig 4.1) si se tienen 10 emisoras, el cromosoma tendrá una longitud de 10. Los elementos de la cadena se codifican con ceros (0) y unos (1); si el elemento de la cadena es 0 la emisora no es incluida dentro del portafolio pero si es 1 la emisora si se incluye dentro del portafolio. Si los elementos 2,5,8 de la cadena tienen unos entonces el portafolio generado incluye las emisoras 2,5,8.

Entonces definimos:

$$x_j = 0 \text{ ó } 1 \quad j \in \{1, \dots, n\}$$

donde:

$n$  = número de emisoras que serán elegibles para generar el portafolio (Tamaño del cromosoma ).

$$x_j = \begin{cases} 1 & \text{si la emisora } j \text{ es seleccionado} \\ 0 & \text{de otra forma} \end{cases}$$



## Codificación del Portafolio que incluye las Emisoras 2,5,8

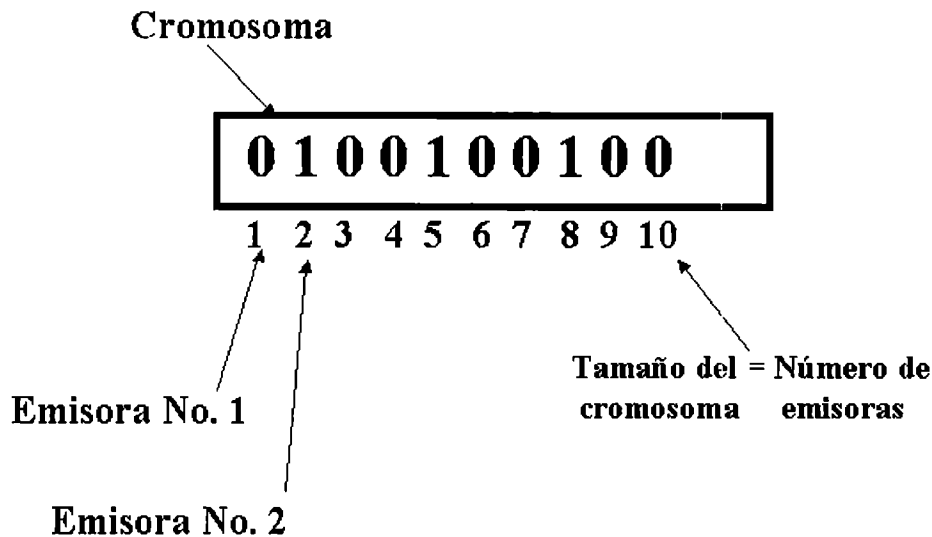


Fig. 4.1 Ejemplo de codificación del portafolio con AGs

De esta forma solo los elementos de la cadena cuyo valor sea “1” representan al portafolio generado.

### 4.1.3 Funciones de aptitud.

La Función de aptitud es entendida como una función de evaluación que juega el rol de ambiente, valorando soluciones en términos de “adecuación” (Michalewicz [85]). Para este modelo es posible seleccionar una de entre tres posibles funciones de aptitud:

1. La primera función de aptitud es el rendimiento del portafolio. Se busca la maximización del rendimiento, es decir el portafolio que muestre el mejor rendimiento.

El rendimiento del portafolio es el resultado de la suma ponderada del rendimiento promedio de cada una de las acciones que están incluidas en el portafolio. Para éste caso en particular y como un supuesto, el inversionista elige una participación igual de los activos que desea incorporar. Dentro de éste modelo el rendimiento se calculo de la siguiente forma:

$$R = \sum_j w_j r_j$$

donde:

R : Rendimiento del portafolio.

w<sub>j</sub>: Ponderación sobre el activo j

r<sub>j</sub>: Promedio de rendimiento de la activo j

El rendimiento modelado con AG es el siguiente:

$$R = \sum_j w_j r_j x_j$$

donde:

R : Rendimiento del portafolio.

w<sub>j</sub>: Ponderación sobre el activo j

r<sub>j</sub>: Promedio de rendimiento del activo j

$$x_j = 0 \text{ ó } 1 \quad j \in \{1, \dots, n\}$$

$$x_j = \begin{cases} 1 & \text{si la emisora } j \text{ es seleccionado} \\ 0 & \text{de otra forma} \end{cases}$$

La segunda función de aptitud es la Varianza del portafolio, que contrario a la anterior busca minimizar el menor valor de la función.

Cálculo de la Varianza en portafolios de inversión.

La varianza del portafolio se define como:

$$\sigma_p^2 = w' \Sigma w$$

donde:

$W$  : Vector de ponderaciones de cada emisora del portafolio

$\Sigma$  : Matriz de Varianzas y Covarianzas de los rendimientos de las emisoras del portafolio.

Para el caso de este modelo las ponderaciones se consideran iguales para cada activo, quedando la varianza del portafolio como sigue:

$$\sigma_p^2 = \left(\frac{1}{N}\right)^2 \sum_{i=1}^N \sum_{j=1}^N \sigma_{i,j}$$

donde

$N$ : número de emisoras del portafolio

La varianza del portafolio modelada con AG es

$$\sigma_p^2 = \left(\frac{1}{N}\right)^2 \sum_{i=1}^N \sum_{j=1}^N \sigma_{i,j} x_j$$

donde

$N$ : número de emisoras del portafolio

$$x_j = 0 \text{ ó } 1 \quad j \in \{1, \dots, n\}$$

$$x_j = \begin{cases} 1 & \text{si la emisora } j \text{ es seleccionado} \\ 0 & \text{de otra forma} \end{cases}$$

La segunda función de aptitud es la Varianza del portafolio, que contrario a la anterior busca minimizar el menor valor de la función.

Cálculo de la Varianza en portafolios de inversión.

La varianza del portafolio se define como:

$$\sigma_p^2 = w' \Sigma w$$

donde:

$W$  : Vector de ponderaciones de cada emisora del portafolio

$\Sigma$  : Matriz de Varianzas y Covarianzas de los rendimientos de las emisoras del portafolio.

Para el caso de este modelo las ponderaciones se consideran iguales para cada activo, quedando la varianza del portafolio como sigue:

$$\sigma_p^2 = \left(\frac{1}{N}\right)^2 \sum_{i=1}^N \sum_{j=1}^N \sigma_{i,j}$$

donde

$N$ : número de emisoras del portafolio

La varianza del portafolio modelada con AG es

$$\sigma_p^2 = \left(\frac{1}{N}\right)^2 \sum_{i=1}^N \sum_{j=1}^N \sigma_{i,j} x_j$$

donde

$N$ : número de emisoras del portafolio

$x_j = 0$  ó  $1 \quad j \in \{1, \dots, n\}$

$$x_j = \begin{cases} 1 & \text{si la emisora } j \text{ es seleccionado} \\ 0 & \text{de otra forma} \end{cases}$$

La misma ponderación de la participación de cada emisora dentro del portafolio se considero ya que, suponiendo varianzas y correlaciones iguales, al tener un portafolio con ponderaciones iguales de cada activo la varianza del portafolio tiende a cero con un número grande de emisoras [66].

Como se observa es necesario el cálculo de la matriz de Varianzas y Covarianzas. Para esto se utilizó la herramienta incluida en EXCEL para el cálculo la matriz de Varianzas y Covarianzas.

Esta herramienta devuelve el promedio del producto de desviaciones de puntos de datos de las medias respectivas. La covarianza es una medida de la relación entre dos rangos de datos (Ayuda Microsoft Excel 2000). La fórmula utilizada por EXCEL es:

$$Cov(X,Y) = \frac{1}{n} \sum_{i=1}^N (x_i - \mu_x)(y_i - \mu_y)$$

2. La última se refiere como función de aptitud al índice resultado de la división del rendimiento del portafolio entre la Varianza del portafolio. Para éste caso se busca encontrar el índice que mejore la función de aptitud. Éste índice permite minimizar riesgo y maximizar rendimiento simultáneamente.

#### Rendimiento/Varianza

El criterio para la selección del portafolio óptimo es un conjunto de acciones que evidencien mayor rendimiento con la menor Varianza simultáneamente.

Este se define como la razón rendimiento varianza, que indica que el máximo rendimiento y la mínima varianza llevan al índice en la misma dirección, de tal manera que se busca el máximo valor posible.

#### **4.1.4 Correlaciones**

Un criterio muy importante para la generación de un portafolio es que no exista una correlación positiva muy grande entre emisoras del portafolio, por éste motivo uno de los parámetros que el usuario puede fijar es el límite máximo de correlación entre las emisoras del portafolio .

Por lo anterior, al seleccionar alguna de las funciones de aptitud disponibles, también es posible fijar un límite de correlación máximo permisible, se da la facilidad de fijar la correlación máxima entre emisoras del portafolio, esto con el fin de garantizar que el portafolio sugerido cumpla plenamente con las preferencias del usuario dentro del modelo.

La Correlación mide la relación entre dos conjuntos de datos medidos para que sean independientes de la unidad de medida. El cálculo de la correlación de población devuelve la covarianza de dos conjuntos de datos dividida por el producto de sus desviaciones estándar.

Para el cálculo de las correlaciones se utilizó la siguiente ecuación:

$$\rho(X,Y) = \frac{\text{cov}(X,Y)}{(\sigma_x \sigma_y)}$$

Para este caso en particular la covarianza y las desviaciones estándar se obtuvieron de la matriz generada por EXCEL.

#### **4.2 Calculo del Tamaño de Población**

El cálculo del tamaño de Población se calculó de acuerdo al procedimiento sugerido por Hernández, Buckles y Martínez [58], Probably Approximately Correct (PAC) Population Size of a Genetic Algorithm, en donde se presenta

la tabla 3 que indica el tamaño de población para longitudes de cromosoma de 20, 50, 80 y 100, con un error de distancia relativa al cromosoma objetivo del 0.4 y una probabilidad de error del 5%.

La tabla se completa para longitudes de cromosoma de 150, 175, 200, 225 y 250, se muestra a continuación:

Longitud	ln(TamPob)	TamPob
20	4.18965474	66
50	5.89989735	365
80	7.12608727	1244
100	7.83122021	2518
<b>150</b>	<b>9.40566041</b>	<b>12157</b>
<b>175</b>	<b>10.1254704</b>	<b>24971</b>
<b>200</b>	<b>10.816232</b>	<b>49823</b>
<b>225</b>	<b>11.4865404</b>	<b>97396</b>
<b>250</b>	<b>12.1399596</b>	<b>187205</b>

Para el caso se utilizó la fórmula:

$$m > 1/\varepsilon(l \ln 2 + \ln \frac{1}{\partial})$$

donde:

$m$ : Se interpreta como el Tamaño de Población

$l$ : Longitud del cromosoma

$\varepsilon$ : Error asociado con la distancia de Hamming

$\partial$ : Probabilidad del error

Como ejemplo, se calcula el tamaño de población para una longitud de cromosoma de 20 usando la fórmula anterior:

$l$ : 20

$\partial$ : 0.05

$$\varepsilon := \frac{\binom{20}{0}}{2^{20}} + \frac{\binom{20}{1}}{2^{20}} + \dots + \frac{\binom{20}{8}}{2^{20}} \dots$$

Nota: el error se calcula hasta las combinaciones de 20 en 8 debido al que error de distancia relativa al cromosoma objetivo es de 0.4, es decir  $20 \cdot 0.4$ .



Entonces

$$m > 1/0.251722(20\ln 2 + \ln \frac{1}{0.5})$$

$$m = 66$$

Otro ejemplo, calcular tamaño de población para una longitud de cromosoma de 225 usando la fórmula anterior:

$$l : 225$$

$$\partial : 0.05$$

$$\varepsilon := \frac{\binom{225}{0}}{2^{225}} + \frac{\binom{225}{1}}{2^{225}} + \dots + \frac{\binom{225}{90}}{2^{225}} .$$


Nota: el error se calcula hasta las combinaciones de 225 en 90 debido al que error de distancia relativa al cromosoma objetivo que se propone es de 0.4, es decir  $225 \cdot 0.4$ .

Entonces

$$m > 1/0.001632(225\ln 2 + \ln \frac{1}{0.5})$$


$$m = 97396$$

Se graficó la longitud del cromosoma vs. tamaño de población y se observó una tendencia exponencial (Grafica. 4.1 ) por lo que se aplicó la función logaritmo natural al Tamaño de población obteniéndose una tendencia casi lineal (Grafica 4.2).



Grafica 4.1. longitud de cromosoma vs. Tamaño de población

Consecuentemente se realizó la regresión lineal simple para longitud y logaritmo natural del tamaño de población.



Grafica 4.2. Longitud de cromosoma vs. Logaritmo natural del Tamaño de población

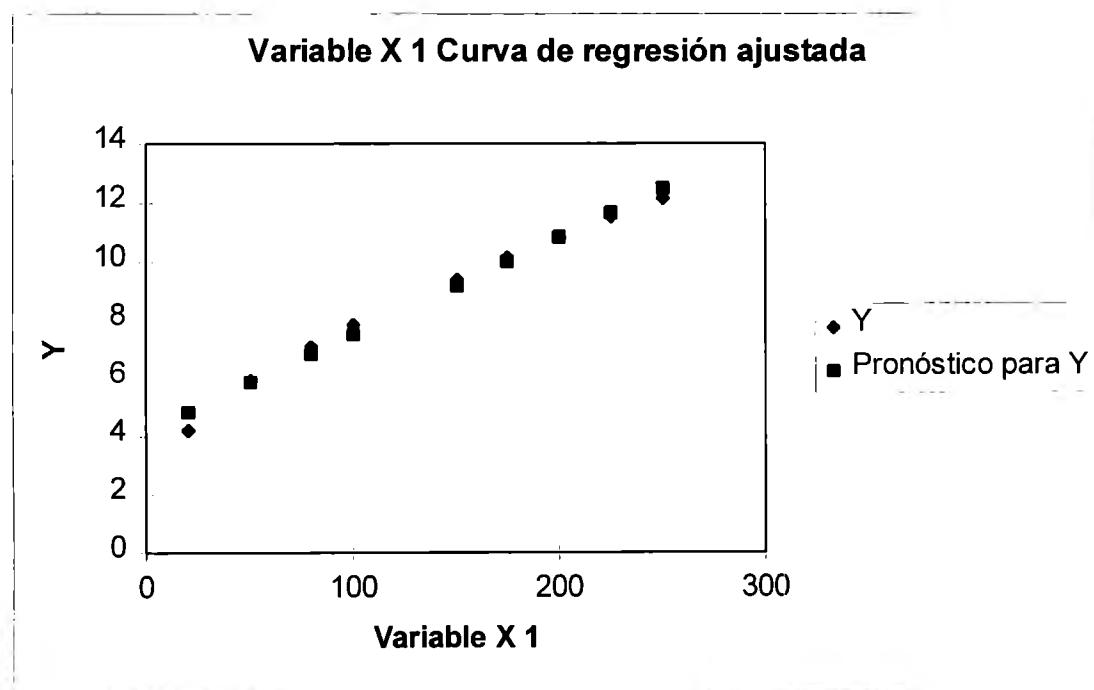
La ecuación que se obtuvo fue:

$$\text{Tamaño de Población} = \text{Exp} (4.17421092 + 0.03316226 * \text{Long. Cromosoma} )$$

Con un Coeficiente de determinación  $R^2$  de 0.9854134 y un valor de F de 472.892399.

Esta ecuación se utiliza para sugerir un tamaño de población de acuerdo al número de emisoras (longitud del cromosoma) que entran al AG del modelo propuesto

El ajuste puede verse en la Grafica 4.3.



Grafica 4.3. Ajuste de la ecuación  $\text{Exp} (4.17421092 + 0.03316226 * \text{Long. Cromosoma} )$  vs datos originales.

### 4.3 Descripción del modelo propuesto

En la Fig.4.2 se muestra el modelo propuesto para toma de decisión en portafolios de Inversión. Este modelo tiene la gran ventaja de estar orientado al usuario, es decir, provee la facilidad de que el usuario interactúe cambiando parámetros del modelo generado, hasta que el modelo le satisfaga acorde a sus preferencias.

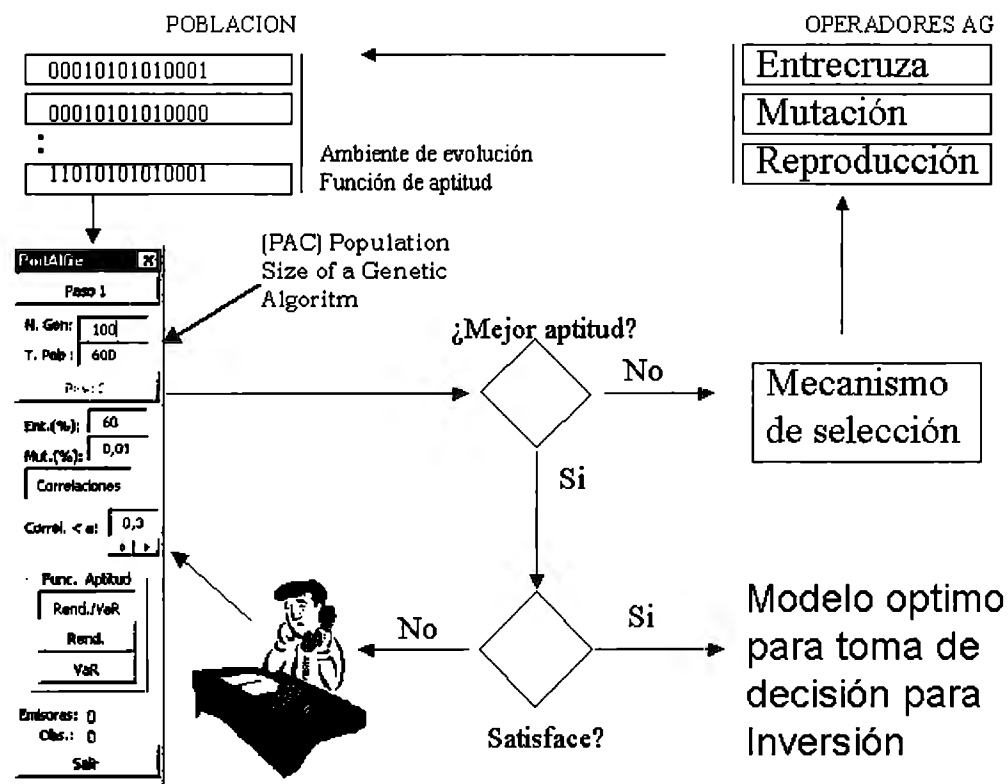


Fig. 4.2 Modelo propuesto

La elección de portafolios de inversión se realiza ingresando o modificando los parámetros del modelo (Fig. 4.3):

1. La elección de una de las tres funciones de aptitud disponibles en el modelo (rendimiento/Varianza, rendimiento ó Varianza). Esta función de aptitud dirige la evolución generando nuevos portafolios con mejor aptitud cada vez por medio de los operadores de cruzamiento, mutación y reproducción.
2. Tomar en cuenta las correlaciones entre emisoras. Permite revisar si existen correlaciones en el portafolio, y si es así, muestra las emisoras y sus correlaciones. Además muestra los portafolios cuya función de aptitud es positiva ( $>0$ ).
3. Fijar un límite máximo permitido de correlación entre emisoras del portafolio. Permite al usuario especificar la máxima correlación permitida en el portafolio.
4. Fijar Parámetros del AG.
  - Número de Generaciones : Permite especificar el número de generaciones que el AG debe generar para llegar a un resultado.
  - Tamaño de Población: Permite sugerir un tamaño de población de acuerdo a la teoría de “PAC learning” aplicado en calcular tamaño de Población en AG’s ( Hernández, Martínez [58]), o que el usuario especifique el tamaño de población que desee.
  - Tasa de entrecruza : Porcentaje de cruzamiento entre los cromosomas. El cruzamiento selecciona una posición dentro de la cadena al azar (llamado punto de cruzamiento) e intercambiar los segmentos de la derecha o izquierda de éste punto con otra cadena particionada similarmente. El cruzamiento provee nuevos portafolios mezclado partes de unos con otros.

- Tasa de mutación: Porcentaje de mutación en los cromosomas. La Mutación crea nuevos individuos modificando uno o varios valores de los genes de un individuo existente, es decir, si la emisora está o no presente en el portafolio.

The screenshot shows a window titled "PortAlGe" with a close button (X). The interface is divided into two main sections: "Paso 1" and "Paso 2".

**Paso 1:**

- N. Gen: 100
- T. Pob.: 600

**Paso 2:**

- Ent.(%): 60
- Mut.(%): 0,01

**Correlaciones:**

- Correl. < a: 0,3

**Func. Aptitud:**

- Rend./VaR
- Rend.
- VaR

At the bottom, there are fields for "Emisoras: 0", "Obs.: 0", and a "Salir" button.

Fig. 4.3 Ventana que muestra los Parámetros del modelo susceptibles a ser modificados por el usuario

La Figura 4.3 muestra, además de los parámetros del modelo, la siguiente información adicional:

1. Número de emisoras: Muestra el número total de emisoras.
2. Número de Observaciones: Muestra el número de observaciones de las emisoras (por día, semana, mes, etc.).

Una vez que se genera el mejor portafolio, acorde a la función de aptitud seleccionada, el usuario decide si satisface sus expectativas, si no es así modifica los parámetros del modelo y espera los nuevos resultados, pero si lo satisface entonces ha encontrado la decisión óptima del modelo.

La idea principal del modelo es dar la mayor ayuda posible al usuario para que la selección del portafolio sea rápida y satisfactoria. Es por esto que el AG sugiere el tamaño de población (PAC-Learning), además de un rango en la tasa de cruzamiento y mutación.

## 5. RESULTADOS

Para establecer las ventajas de este modelo de toma de decisiones se compararon sus resultados de los rendimientos con las siguientes metodologías:

1. Modelo de programación Lineal propuesto por Speranza [107] que simplifica el modelo de Markowitz [79].
2. Índice de precios y cotizaciones de la Bolsa Mexicana de Valores
3. Capital Asset Pricing Model..Para el rendimiento de tasa libre de riesgo se tomo la tasa de CETES a 28días, y para el rendimiento de mercado el rendimiento del Índice de Precios y Cotizaciones de la Bolsa Mexicana de Valores.
4. Combinación del modelo de Programación Lineal de Speranza y el Modelo propuesto, Se corrió el modelo de Programación lineal propuesto por Speranza, y los resultados de este se utilizaron como entrada para el modelo propuesto con AG.
5. Combinación del modelo propuesto y el de Programación Lineal de Speranza . Se corrió el modelo de AG propuesto y los resultados de este se utilizaron como entrada para el modelo Programación lineal propuesto por Speranza.

Se seleccionaron dos grupos de emisoras de la Bolsa Mexicana de Valores (tomadas de REUTERS). El primer grupo de emisoras se toman del periodo del primero de julio al el 11 de noviembre de 1998, con 96 valores de rendimiento para un total de 31 emisoras. El segundo Grupo se selecciono entre el período del 2 de Mayo de 2001 y el 30 de Agosto de 2001, con 87 valores de rendimiento para un total de 149 emisoras.



- El grupo de 31 emisoras fue el siguiente:

<b>1</b> Tvaztecacpo	<b>2</b> Televisacpo	<b>3</b> Cemex	<b>4</b> Cifrac
<b>5</b> Giganteb	<b>6</b> Elektracpo	<b>7</b> Masecab	<b>8</b> Kofl
<b>9</b> Kimbera	<b>10</b> Ahmsa	<b>11</b> Dina	<b>12</b> Hilasal
<b>13</b> Bimbo	<b>14</b> Gmodeloc	<b>15</b> Ica	<b>16</b> Liverpool
<b>17</b> Femsa	<b>18</b> Gcarso	<b>19</b> Dataflux	<b>20</b> Biper
<b>21</b> Apasco	<b>22</b> Soriana	<b>23</b> Gigante	<b>24</b> Comercialmex
<b>25</b> igma	<b>26</b> Maizoro	<b>27</b> Bachoco	<b>28</b> Geo
<b>29</b> Moderna	<b>30</b> Argos	<b>31</b> Peñoles	

- El grupo de 149 emisoras fue el siguiente:

acel s.a . B	ekco	Herdez sadecv	pepsigx ADR	unefon A
alfa sa A	elektra gpo A	Hilsal mexicana A	pepsigx CPO	Valle jugos B
almacenadora ACCE	elektra gpo B	Hogar Consorcio B	planeacion y Proyec B	valuegf o
ALSEA	elektra gpo CPO	hylsamex B	posadas A	vitro A
america movil A	empaques ponderosa B	ICA soc Controlad	posadas L	vitro ADR
amaerica movil L	far-ben B	ICA soc Controlad ADR	qumma B	Wal Mart C
apasco sa	fomento econom mex ub	imsa gpo ADR	Radio centro ADR	Wal mart CADR
ara	fomento econom mex ubd	imsa gpo ubc	Radio centro CPO	Wal mart V
argos emb B	fragua corp B	ind. Automotriz sa	saba casa	wings B
asur aerop se B	Gaccion B	industrias CH B	saba casa ADR	
bachoco ind ubl	Gcarso A1	inter de ceramica ADR	san luis Corp A	
banamex accival gf o	gcorvi UBL	inter de ceramica UB	san luis CPO	
bimbo gpo A	Gemb Unidas B	inter de ceramica ULD	Santander serfin B	
camesa gpo ind	General de Seguros A	invex gpo fin O	savia A	
cementos chihuahua B	General de Seguros B	iusacell gpo V	savia ADR	
cemex cpo	geo corporacion B	ixe Gpo financ O	seg comAmerica A	
cid mega resort	GFBanorte O	Kimbrly Clark Mex A	seg comAmerica B	
cintra sa A	GFBVBancomer O	Kimbrly Clark Mex ADR	simec ADR	
citygroup mexico	GFBital L	Kimbrly Clark Mex B	simec B	
collado sa	GF inbursa O	KOF coca cola femsa	soriana B	
com mex ubc	Gigante Gpo	KOF coca cola femsa L	sinkro A	
continental grupo	Gind durango A	lamosa B	tekchem A	
control de farmacia B	Gind Durango ADR	liverpool 1	telecom A1	
convert. Ind. B	Gind saltillo B	liverpool c-1	telemx A	
corp interam de ent B	Gmacma SA B	maizoro sadecv	telmex AADR	
copr moctezuma	Gmarti sa	maseca GIADR	telmex L	
cydsa sa A	Gmaseca(grupa) B	maseca GI B	telmex LADR	
dataflux B	Gmex desarrollo B	medica sur A	televisa ADR	
dermet de mexico sa B	Gmexico B	medica sur B	televisa CPO	
desc soc fom A	gmodelo C	mimsa C	tvazteca ADR	
desc soc fom B	gmoderna	movil acces B	tvazteca CPO	
desc soc fom C	Gnacional Provincia	nadro B	trmm AADR	
dixon ticonderoga	Gomo Gpo	panamco	trmm LADR	
duty free sadecv	Gpalacio de Hierro 1	parras A	tubos de acero	
edoardo sa B	Gsamborns(com car) B	penoles	tubos de acero ADR	

Para correr los modelos de Programación Lineal se utilizó el Software Statistical Analysis System (SAS).

Todos los resultados Obtenidos con el modelo de AG propuesto, utilizaron la propuesta de PAC descrita en el presente trabajo, para el tamaño de población del AG.

Los rendimientos del Índice de Precios y Cotizaciones son los siguientes:

Para el caso de 31 emisoras

ipc 11 nov 1998	4117.69
ipc 12 nov 1998	4028.7
Rendimiento	-2.161%

<http://www.banxico.org.mx>

fuelle banco de México información financiera y económica bolsa mexicana de valores IPC

Para el caso de 149 emisoras

ipc 30 agosto 2001	6310.17
ipc 31 agosto 2001	6310.7
Rendimiento	0.00839%

<http://www.banxico.org.mx>

fuelle banco de México información financiera y económica bolsa mexicana de valores IPC

Los resultados Obtenidos se resumen en la siguiente Tabla:

Método	No Emisoras resultantes	Rendimiento	Rend. CAPM	Rend. IPC
AG31	12	0.00033	0.0058331	-2.16%
PL31	14	0.14570	0.0055624	-2.16%
AG31PL	5	<b>0.56190</b>	0.0058558	-2.16%
PL31AG	3	0.00226	0.0060314	-2.16%
AG149	55	0.00140	-0.0037635	0.008%
PL149	30	0.04970	-0.0050041	0.008%
AG149PL	6	<b>0.25840</b>	-0.0046298	0.008%
PL149AG	6	0.01167	-0.0067145	0.008%

Tabla 5.1 Resultados obtenidos con los diferentes métodos.

Nota: Las salidas completas de las corridas de estos modelos se encuentran en los apéndices.

Donde:

AG31 : Indica modelo de AG con 31 emisoras.( Apéndice B)

PL31 : Indica el modelo de programación lineal propuesto por Speranza con 31 emisoras. (Apéndice A)

AG31PL : Indica que el portafolio resultado de AG31 se proceso con el modelo de programación lineal propuesto por Speranza. (Apéndice F)

PL31AG : Indica que el portafolio resultado de PL31 se proceso con el modelo de AG propuesto. (Apéndice E)

AG149 : Indica modelo de AG con 149 emisoras. (Apéndice D)

PL149 : Indica el modelo de programación lineal propuesto por Speranza con 149 emisoras. (Apéndice C)

AG149PL : Indica que el portafolio resultado de AG149 se proceso con el modelo de programación lineal propuesto por Speranza. (Apéndice H)

PL149AG : Indica que el portafolio resultado de PL149 se proceso con el modelo de AG propuesto. (Apéndice G)

En la tabla 5.1 se muestran los resultados obtenidos. Se aprecia que el modelo propuesto con AG a pesar de no generar los mejores resultados de rendimiento, si genera rendimientos positivos, lo cual contrasta con el rendimiento del IPC que es negativo para el caso de 31 emisoras y con el rendimiento del CAPM para el caso de 149 emisoras.

Los rendimientos que se generan con el modelo de programación lineal de Speranza son mejores que el rendimiento que propone el modelo de AG, sin embargo cuando se utilizan la combinación de AG y Programación lineal en ese orden, es decir procesar la salida de AG y después aplicar la programación lineal, genera los mejores rendimientos de todos los métodos utilizados.

Los resultados de la combinación de AG y programación lineal muestran portafolios con rendimientos sensiblemente mejores comparados con los rendimientos del IPC y con los de CAPM.

## **6. CONCLUSIONES Y RECOMENDACIONES**

### **6.1 Conclusiones:**

- Este modelo de toma de decisiones para portafolio de inversión es otra alternativa para la selección de portafolios de inversión, si bien comparado con el modelo de programación lineal, no muestra los mejores resultados, si permite al tomador de decisiones combinarlo con el de programación lineal y así obtener mejores rendimientos.
- Este modelo de GA permite obtener rendimientos positivos a pesar de que el IPC no tenga un desempeño positivo en cuanto a rendimientos.
- Este modelo de toma de decisiones para portafolio de inversión mejora la estrategia y posibilidades del usuario para tomar una buena decisión de inversión acorde a sus preferencias y necesidades.
- Este modelo permite al usuario seleccionar el portafolio que le proporcione: maximización del rendimiento, minimización del riesgo o ambos simultáneamente por medio de la razón rendimiento varianza que muestra el mayor rendimiento con el menor riesgo. Para las opciones anteriores es posible fijar un máximo de correlación permitido entre emisoras, y con la facilidad de verificar que los portafolios no sobrepasen este limite de correlación.
- Los portafolios que se obtienen como resultado la Función de Aptitud de rendimiento pueden garantizar una varianza menor cuando la correlación que se fije sea baja

- El uso del PAC para el calculo del tamaño de población, dependiendo del número de emisoras que entran a análisis, con una tasa de entrecruza mayor al 40% y con la menor tasa de mutación posible, garantizan los mejores resultados. La magnitud de estos parámetros se sugieren por omisión para que el tomador de decisiones interactúe el menor número de veces posible.

## 6.2 Recomendaciones:

- Los rendimientos que se ingresen al modelo determinarán la magnitud del rendimiento y riesgo, esto se debe a que estos datos pueden ser diarios, semanales, mensuales e incluso anuales y con cantidades de datos variables (un año de rendimientos mensuales o un año de rendimientos diarios) y dentro de esos periodos pueden existir eventos extraordinarios (11 de septiembre 2001, quiebra de ENRON, etc)
- Modificar el modelo para que seleccione las emisoras que participaran y su correspondiente ponderación dentro del portafolio. Agregando un carácter que será representado por una letra la cual se mapeará al número correspondiente y así poder calcular las ponderaciones.
- Facilidad de agregar al modelo nuevas Funciones de aptitud que proponga o necesite el usuario
- Agregar al modelo de AG propuesto la opción de proceso de la salida con el modelo de programación lineal propuesto por Speranza, esto garantizaría que el portafolio resultante tendrá un buen rendimiento y cumplirá con las expectativas del tomador de decisiones.

## 7. TRABAJOS FUTUROS

### 7.1 Modelado de portafolio con cadenas con en carácter ASCII de 0 a 100

Codificación del portafolio con AG's.

Para la codificación del portafolio se utiliza una cadena de caracteres ASCII por ejemplo, esta cadena es el cromosoma dentro del AG. Este cromosoma representa a todo el conjunto de emisoras que se analizan. Es decir, el AG genera cadenas de caracteres ASCII correspondientes a su valor de 0 a 100, con un tamaño igual al número de emisoras que serán elegibles para generar el portafolio (Ingresadas por el usuario). Las posiciones de la cadena son mapeadas con los nombres de las emisoras.

Por ejemplo Fig. 7.1 si se tienen 10 emisoras, el cromosoma tendrá una longitud de 10. Los elementos de la cadena se codifican con ceros (0) y otro carácter; si el elemento de la cadena es 0 la emisora no es incluida dentro del portafolio pero si no la emisora si se incluye dentro del portafolio con el porcentaje de participación correspondiente al carácter ASCII. Si los elementos 2,5,7,8,10 de la cadena tienen caracteres diferentes de cero entonces el portafolio generado incluye las emisoras 2,5,7,8,10.

La restricción que se debe cumplir radica en que las sumas de los porcentajes de participación de las emisoras incluidas en el cromosomas debe ser 100%.

En la Fig. la suma de las participaciones es de:

$$\#(35)+ 1(49)+ a(97)+ <(60)+ @(64)= 305\%$$

por lo tanto este cromosoma no seria tomado en cuenta.

Una variante de este modelo es ampliar el universo de caracteres ASCII que pueden ser considerados dentro del cromosoma, como es sabido,



los caracteres ASCII son 256, para este caso se tomaría el carácter “0” como la no admisión de la emisora en el portafolio. Con esta consideración se toman en cuenta solos 255 caracteres, esto da una ponderación de 0.3921568 resultado de (100/255) por cada numero correspondiente al carácter ASCII incluido en el cromosoma.

Así, si tomamos el mismo ejemplo de la Fig.7.1 se obtiene:

$$\#(35*0.3921568)+1(49*0.3921568)+a(97*0.3921568)+ (60*0.3921568)+ @ (64*0.3921568)= 119.607843\%$$

$$\#(13.7254902)+(119.2156863)+a(38.0392157)+<(23.5294118) +@(25.0980392 )=119.607843\%$$

Con esta variación se obtiene mas precisión en los porcentajes de participación de cada activo en los portafolios.

Una vez que se tienen estos porcentajes Realizar los cálculos de rendimiento y varianza con las mismas ecuaciones que se utilizaron en este trabajo.

## Codificación del Portafolio que incluye las Emisoras 2,5,7,8,10

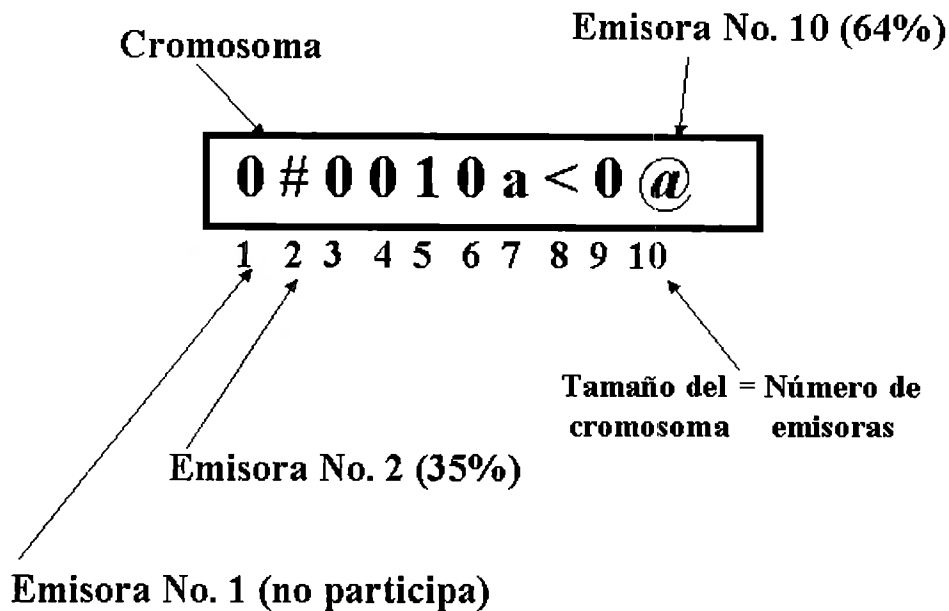


Fig. 7.1 Ejemplo de codificación del portafolio con AG's

### **7.2 Determinación del número de emisoras que participarán en un portafolio.**

Dada la modelación de portafolio correspondiente a este trabajo la determinación del número de emisoras que intervendrán en el portafolio puede determinarse que al generar la primera generación se creen portafolios solo con el numero determinado de emisoras.

Dado que la mutación y la entrecruza pueden intervenir cambiando el numero de emisoras dentro del portafolio este procedimiento no garantiza que el portafolio final tenga el número determinado de emisoras a menos que durante cada generación se trabaje con los cromosomas que cumplan con criterio de número de emisoras, esta

condición indica que se tendrá que trabajar con tamaños de población heterogéneos entre generaciones.

### **7.3 Optimización del Manejo de los cromosomas.**

Esta consideración nos permite evaluar las poblaciones dentro de cada generación y obtener dos Funciones de aptitud por cada cromosoma, esto se realiza simplemente evaluando el cromosoma al derecho y al revés.

Como ejemplo:

Cromosoma	101011
Posición al derecho	123456
Posición al revés	654321

La posición al derecho indica que en las posiciones 1,3,5 y 6 se encuentran los unos, mientras que en la posición al revés la ocupan en las posiciones 1,2,4 y 6.

Con esta forma de trabajar se pueden tener poblaciones de la mitad de tamaño de la original y así disminuir el tamaño de memoria en la computadora donde se implemente.

## 8. BIBLIOGRAFÍA

- [1] Allen Bradley, Case-Based Reasoning: Business Applications. Communications of the ACM. March 1994. Vol.37.No 3.
- [2] Anand T., Kahn G., Nielsen A., 1993. Focusing Knowledge-Based Techniques on Market Analysis. IEEE expert ,August, 1993.
- [3] Angluin, D., Smith, C. Inductive Inference: Theory and Methods. ACM Comp. Surveys, 15(3), 237-270.
- [4] Austin, S., 1990. An untrouction to Genetic Algorithms, AI expert, March 1990.
- [5] Bancroft, John. Servicers eye new technologies to increase profitability
- [6] Real Estate Finance Today; Washington; Feb 3, 1997;
- [7] Baba, N.; Inoue, N.; Asakawa, H. 2000. Utilization of neural networks and GAs for constructing reliable decision support systems to deal stocks
- [8] Neural Networks, 2000. IJCNN 2000, Proceedings of the IEEE-INNS-ENNS International Joint Conference on , Volume: 5 , 2000 Page(s): 111 -116 vol.5
- [9] Bao, Paul; Wong, Hakman. 1998. A Hybrid Theory Model based on Genetic Algorithm and Vector Quantization. Systems, Man, and Cybernetics, 1998. 1998 IEEE International Conference on , Volume: 5 , 1998 Page(s): 4301 -4306 vol.5
- [10] Bennet, W., Tilman, L. Measuring Yield Curve Risk Using Principal Components Analysis, Value at Risk, and Key Rate Durations. Th Journal of Portfolio Management, Summer 1997.
- [11] Bijan Fazlollahi; Rustam Vahidov. 2001. A method for generation of alternatives by decision support systems. *Journal of Management Information Systems*; Armonk; Fall 2001
- [12] Black F, Litterman R., 1992. Global portfolio optimization, Finanacial analysis journal. September-October 1992.
- [13] Boritz J, Kennedy D., 1995. Effectiveness of Neyral Network Types for Prediction of Business Failure. Expert Systems whit Applications, Vol 9, No. 4, pp 503-512, 1995.
- [14] Bouman M., Human Diagnostic Reasoning By Computer: An illustration From Financial Analysis.

- [15] Booker, L. B., Goldberg, D. E., Holland, J. H., Classifier Systems and Genetic Algorithms. Machine Learning. Paradigms and Methods. A Bradford Book, MIT Press, Cambridge, Massachusetts, London, England.
- [16] Bramer M. 1988. Expert systems in business: a British perspective. Expert Systems, May 1988, Vol 5, No 2.
- [17] Braun, H. & Chandler J. Predicting Stock Market Behavior Through Rule Induction: An application of the learning. Examples Approach, Decision Sciences, 18, 3, 1987.
- [18] Cairó, Osvaldo. Apuntes de Inteligencia artificial, Doctorado en administración, itesm, campus ciudad de México. 1999.
- [19] Carandang, R. Derivative portfolio risk management using a value-at-risk framework. Computational Intelligence for Financial Engineering (CIFEr), 1997., Proceedings of the IEEE/IAFE 1997 , 1997 Page(s): 260 –265
- [20] Charniak E. Bayesian Networks without Tears. AI Magazine. Winter 1991.
- [21] Chaudhury, A., et al. The economic Foundation for Neural Computing Systems, Advances in Artificial Intelligence in Economics, Finance, and management. Vol. 1. Jai pressinc.1994
- [22] Chi R., Chen M., Melody K., 1993. Generalized Case-based Reasoning System for Portfolio Management. Expert Systems whit Applications, Vol 6, pp 67-76, 1993.
- [23] Citygroup Inc. anual report 2000
- [24] Coello, C., 1995. Introduccion a los algoritmos Geneticos, Soluciones avanzadas, Enero 1995, Mexico D.F. Introduccion al concepto de algoritmos geneticos con un ejemplo aplicado a finanzas.
- [25] Dhar V. Croker A.,1988. Knowledge-Based decision Support in Business: Issues and Solution. IEEE Expert, Spring 1988.
- [26] Darsa D. Expert systems handle insurance paper flow Real Estate Finance Today; Washington; Dec 8, 1997; Volume:14, Issue: 25
- [27] De Jong, K., Spears, W., Gordon, D., 1992. Using Genetic Algorithms for Concept Learning. Operations research and Artificial Intelligence. The integration of problem-Solving Strategies. Kluwer Academic Publishers, Boston/Dordecht/Lodon, 1992.

- [28] Dean T., Allen J & Aloimonos Y. Artificial Intelligence, Theory and Practice. Benjamin Cummings Publishing, USA, 1995.
- [29] Del Valle, David. 1999. Diseño De Un Portafolio Óptimo: Un Criterio De Inteligencia Artificial Y Valor Al Riesgo. Trabajo para la materia: Inteligencia artificial, Doctorado en administración, itesm, campus ciudad de México. 1999.
- [30] Dhar V. Croker A., Knowledge-Based decision Support in Business: Issues and Solution. IEEE Expert, Spring 1988.
- [31] Dinesh M., Ramakrishnan P. Four models for a decision support system. Information & Management. Amsterdam; Jan 1999
- [32] Dirks S., Kingston J., Haggith M. 1995. Development a KBS for personal financial planning guided by Pragmatic KADS. Expert Systems whit Applications, Vol 9, No. 2, pp 91-101, 1995.
- [33] Dorsey, R., Jhonson, J., Mayer, W. A genetic Algorithm for the training of feedforward Neural Networks. Systems, Advances in Artificial Intelligence in Economics, Finance, and management. Vol. 1. Jai pressinc. 1994
- [34] Duda ,R., Hart, P. Pattern Classification and Scene Analisis. Wiley, 1973.
- [35] Duda R., et al. Syntel, 1987. Using a Functional Language for Financial Risk Assessment. IEEE Expert, Fall 1987.
- [36] Dueck G., Winker P. 1992. New concepts and algorithms for portfolio choice. Applied stochastic Models and data analysis, Vol. 8, pp 159-178. 1992.
- [37] Dym S., 1997. Credit Risk Analysis fro Developing Country Bond Portfolios. The journal of Portfolio Management, winter 1997.
- [38] Ein-Dor P. The Fourth International Workshop on Artificial Intelligence in Economics and management. Spring 1997, American Association for Artificial Intelligence.
- [39] Elmer P., Borowski D., 1988. An expert system Approach to Financial Analysis: The case of S&L Bankruptcy. Finanacial Management, Autumn 1988.
- [40] Estivil, C., 1995. Construcccion de Bases de Conocimiento con computacion Evolutiva, Soluciones Avanzadas, Eneiro 1995, Mexico D.F.
- [41] Fawcett, T. et. al. AI Approches to Fraud Detection and Risk Management. Summer 1998. American Association for Artificial Intelligence.

- [42] Fischer D. & Jordan R. Security Analysis and portfolio management. Prentice-Hall International inc. 1991.
- [43] Fleming, P. J., Chipperfield, A., 1996. Introduction to Genetic Algorithms. Memorias II Taller Internacional de Procesamiento en Paralelo. IMMAS, UNAM, Julio 1996.
- [44] Fleming, P. J., Fonseca, C. M., 1996. Genetic Algorithms in Control Systems Engineering. Memorias II Taller Internacional de Procesamiento en Paralelo. IMMAS, UNAM, Julio 1996.
- [45] Fogler H., 1995. Investment Analysis and New Quantitative Tools. The journal of Portfolio Management, winter 1995.
- [46] Forrest, S., 1996. Genetic Algorithms. ACM Computing Surveys, Vol 28, No. 1 March 1996.
- [47] Franks, E. A decision Support System for Revising Portfolios to Achieve Pre-Specified Target Returns after Inflation with Reliability and Efficiency. Investment management: Decision Support and Expert Systems.
- [48] Frigerio, Christian. juin 13, 2001. Banca Monte dei Paschi di Siena SpA, Paris, Published by Standard & Poor's, a Division of The McGraw-Hill Companies
- [49] Fukunaga, A.S. 2000. Genetic algorithm portfolios, Evolutionary Computation, 2000. Proceedings of the 2000 Congress on , Volume: 2 , Page(s): 1304 -1311 vol.2
- [50] Gately, E., Neural Networks for financial forecasting. Jhon Wiley & sons, Inc. New York, 1996.
- [51] Gilbert, J., Artificial Intelligence on Wall Street: An Overview and Critique of Applications in the Finance Industry. November 13, 1995 ,Written for COSI 35, taught by Jordan Pollack. Brandeis University, Department of Computer Science
- [52] Goldberg E. David., Genetic Algorithms in Search, Optimization, and Machine Learning. Addison-Wesley Publishing, 1989.
- [53] Goldman sachs group inc. 2001. Published by Standard & Poor's, a Division of The McGraw-Hill Companies, New York.
- [54] Golub B., Tilman L., 1997. Measuring Yield Curve Risk Using Principal Components Analysis, Value at Risk, and Key Rate Durations. The journal of Portfolio Management, summer 1997.

- [55] Hamza F., Janssen J. & Ruelas G. Performance analysis of mean semivariances Portfolio Models applied to belgium stock Market. Belguian Journal of Opreation Research, Statistic and Computer Science. 1998.
- [56] Hawley D., Johnson J., Raina D., 1990. Artificial Neural Systems: A new Tool for financial decision-Making. Finanacial analysis Journal. November-December 1990.
- [57] Hayes-Roth F., Jacobstein, N. The state of Knowledge Systems. Communications of the ACM. March 1994. Vol.37.No 3.
- [58] Hernandez, A. Buckles, B., Martinez, A. The Probably Approximately Correct (PAC) Population Size of a Genetic Algorithm. IEEE, 199-202. 2000
- [59] Heuer S., Koch U., Cryer C., 1988.INVEST: An expert System for Financial Investments. IEEE Expert Summer 1988.
- [60] Ho, T., et. al. VAR Analytycs: Portfolio Structure, Key Rate Convexities, and VAR Betas. The Journal of Portfolio Management, Fall 1996.
- [61] Humpert B., Holley P., Expert Systems in Finance Planning, Expert systems, May 1988. Vol.5, No. 2.
- [62] Humpert B., Holley P., 1988. Expert Systems in Finance Planning, Expert systems, May 1988. Vol.5, No. 2.
- [63] Johnson, L., Redman A., Tanner J.,; Utilization and applications of business computing systems in corporate real estate. The Journal of Real Estate Research; Sacramento; 1997; Volume: 13,Issue:2.
- [64] Johnson, J.,Whinston A., Advances in Artificial Intelligence in Economics, Finance, and Management. Vol. 1. Jai press inc. 1994.
- [65] Janssen J., Ruelas G, Performance analysis of mean-weighted semivariances models applied to belgium stock market.
- [66] Jorion P. 1992. Portfolio Optimization in Practice. Financial Analysis journal, January-February, 1992.
- [67] Kindel W. et al. PFPS: Personal Financial Planning System.
- [68] Klein M. & Methlie L. Knowledge-Based Decision Support System, with aplication in business. Second edition, Wiley, England, 1995.



- [69] Kodratiff, Y., Michallski, R. Machine Learning: An Artificial Intelligence Approach. Volume III. Morgan Kaufman, 1990.
- [70] Konno, h., Yamazaki, H. Amean Absolute Portfolio Optimization Model and its Applications to tokyo Stock Market, Management Science, 1991.
- [71] Koza, J.R., 1992. Genetic "Programing on the programming of computers by means of natural selection", the MIT press, 1992, 819 p.
- [72] Langley, P., Simon, H. Applications of Machine Learning and Roule Induction. . Communications of the ACM. November 1996, Vol 38. No.11.
- [73] Laudon, Traver, Laudon. Information Technology and Society. Course Technology, Inc. Cambridge,1996.
- [74] Liang T., Chen K., Issues Developing Expert Systems for Program Trading. Investment Management: Decision Suport and expert Systems.
- [75] Liebowitz, J. Worldwide Perspectives and Trends in Expert Systems, An Analisys Based on the Three World Congress on Expert systems. Summer 1997, American Association for Artificial Intelligence.
- [76] Liepins, G. E., Hilliard, M. R., Genetic Algorithms Applications to set Covering and Traveling Salesman Problems.
- [77] Linter, J, 1965. The evaluation of risky assets and the selection of risky investments in stock portfolios and capital Budgets. Reviews of economics and statistics 47:13-37.
- [78] Madhavan R., 1994. Goal-Based Reasoning for securities Analysis. AI Expert, February 1994.
- [79] Markowitz, H., Portafolio Selection. Journal of finace , June, 1952.
- [80] Martello S., Toth P., Knapsack Problems, Algoritms and Computer Implementations. Ed. Wiley, 1990.
- [81] Martinez, Jesus. 2000. Análisis. Banco Bilbao Vizcaya Argentaria S.A., Madrid . Published by Standard & Poor's, a Division of The McGraw-Hill Companies. 2001,

- [82] Mausser, H.; Rosen, D. 1999. Beyond VaR: from measuring risk to managing risk. Computational Intelligence for Financial Engineering, 1999. (CIFEr) Proceedings of the IEEE/IAFE 1999 Conference on , 1999 Page(s): 163 –178
- [83] Mausser, H.; Rosen, D. 1999. Beyond VaR: parametric and simulation-based risk management tools. Computational Intelligence for Financial Engineering, 1999. (CIFEr) Proceedings of the IEEE/IAFE 1999 Conference on , 1999 Page(s): 159 –162
- [84] Mays E. et al.1987. Organizing Knowledge in Complex Financial Domain. IEEE Expert, Fall 1987.
- [85] Michalewicz, Z. Genetic Algorithms + Data Structures = Evolution Programs. Third Edition, Springer, 1996.
- [86] Michalsky, R.S., Carbonell, J., Mitchell, T. Machine Learning: An artificial Intelligence Approach, Volume II. Morgan Kaufman, 1983.
- [87] Modigliani F., Modigliani L., 1997.Risk-Adjusted Performace. The journal of Portfolio Management, winter 1997.
- [88] Mossin, J. 1966. Equilibrium in capital Market. Econometrica. 34:768-738.
- [89] Mui Ch., McCarthy W., 1987. Applying AI Techniques to Familiarization Phase of Financial Decision Making. IEEE Expert, Fall 1987.
- [90] Myers S., 1988. Notes an an Expert System for Capital Budgeting. Finanacial Management, Autumn 1988.
- [91] Noaln, J. An Intelligent System for Case Review and Risk Assessment in Social Services. Spring 1998, American Association for Artificial Intelligence.
- [92] Orito, Y.; Yamazaki, G. 2001. Index fund portfolio selection by using GA Computational Intelligence and Multimedia Applications, 2001. ICCIMA 2001. Proceedings. Fourth International Conference on , 2001,Page(s): 118–122
- [93] Oldham K, et. Al. Structured Models to assist in justifying investment in knowledge-based systems. Proc Instn Mech Engr, Vol 211 Part B. 1997.
- [94] Park Ch., Han I., Testing for caos in stock volatility the rescaled range analysis. Application of Advanced Information Technologies, pp. 33-40.
- [95] Prasad, K. Adjustment in maching markets: A neural Network Approach. Systems,Advances in Artificial Intelligence in Economics, Finance, and management. Vol. 1. Jai pressinc.1994

- [96] Qureshi, A., Shim J., Siegel J. Artificial intelligence in accounting & business. The National Public Accountant; Washington; Sep 1998; Volume:43, Issue:7
- [97] Rich, E., Knigth, K. Artificial Intelligence. International edition McGraw-Hill 1991.
- [98] Sastri, T. A Neural Network Production Planning System. Systems,Advances in Artificial Intelligence in Economics, Finance, and management. Vol. 1. Jai pressinc.1994
- [99] Sastri, T., English, J. R., Wang, G. N. Neural Networks for time Series Model Identification and Change Detection. Systems,Advances in Artificial Intelligence in Economics, Finance, and management. Vol. 1. Jai pressinc.1994
- [100] Senator T., et al., The Finanacial Crimes Enforcement Network AI Systems (FAIS) Identifying Potential Money Laundering from Reports of Large Cash Transactions. Winnter 1995, American Association for Artificial Intelligence.
- [101] Schwartz, Susana . First Union gauges cardholder risk Bank Systems + Technology; New York; Apr 1998; Vol, 35 Issue: 4.
- [102] Shane B., Fry M., Toro R., The Design of an investment Portfolio Selection Decision Support Systems
- [103] Sharpe, W. Capital Asset Prices. A theory of a market equilibrium under conditions of Risk. Journal of finance 19:425-442, 1964.
- [104] Shaw M., Gentry J.,1988. Using an expert Sytem with inductive Learning to evaluate Business Loans. Financial Management , Autumn 1988.
- [105] Shoaf, J.; Foster, J.A. 1998. The efficient set GA for stock portfolios. Evolutionary Computation Proceedings, 1998. IEEE World Congress on Computational Intelligence., The 1998 IEEE International Conference on , 1998 Page(s): 354 –359
- [106] Siskos, Y; Spyridakos, A; Yannacopoulos, D. Using artificial intelligence and visual techniques into preference disaggregation analysis: The MIIDAS system. European Journal of Operational Research; Amsterdam; Mar 1, 1999;
- [107] Speranza, M.G. Linear Programming Models for Portfolio Optimization. Finance 14. Pp 107-123. 1993.
- [108] Srinivasan V., Kim Y., 1988. Desisgning expert Finanacial Systems: A case study of Corporate Credit Management. Finanacial Management, Autumn 1988.

- [109] Stansfield J., Greenfeld.,1987. Plan Power a comprehensive Financial Planner. IEEE Expert, Fall 1987.
- [110] Stair, Reynolds.,Informtion Systems a Mangerial Approach. Third Edition, Course Technology, Inc. Cambridge,1998.
- [111] Steels L. Components of Expertise. IA Magazine. Summer 1990.
- [112] Steiger D. Enhancing user understanding in a Decision Support System: A theoretical basis and framework. Journal of Management Information Systems; Armonk; Fall 1998, Volume: 15. Issue:2.
- [113] Steven W.Back to the future: A look at today's CMBS market from the year 2000. The Real Estate Finance Journal; Boston; Winter 1997; Volume: 12, Issue:3
- [114] Stuewe R. Financial Management Career Program. Air Force Comptroller; Washington; Apr 1, 1998;Volume: 32, Issue: 2.
- [115] Tanenbaum, A. S., Redes de computadoras. Tercera edición, Prentice may, 1997.
- [116] Trading Portfolios American Express Company 2000
- [117] Trippi, T. A Decision Support System for Real Estate Investment Portfolio Management. Investment management: Decision Support and Expert Systems.
- [118] Trippi, R., Lee, J. Artificial Intelligence in Finance & Investing. IRWIN Professional Publishing, 1996.
- [119] Trippi, R., Turban, E. Neural Networks in Finance and Investing, . IRWIN Professional Publishing, 1996.
- [120] Turban E., Decision Support and Expert Systems: Management Support Systems. Macmillan Illinois University, USA 1993.
- [121] Uryasev, S. 2000. Conditional value-at-risk: optimization algorithms and applications Computational Intelligence for Financial Engineering, 2000. (CIFEr) Proceedings of the IEEE/IAFE/INFORMS 2000 Conference on , 2000 Page(s): 49-57
- [122] Valentine J., Appling Expert Systems to Investment. Financial analysis Journal. November-December 1988.
- [123] Valiant, L. G. A theory of the learnable. Comm. ACM, 27(11), 1134-1142. 1984

- [124] Wen-Shiu Lin; Jiah-Shing Chen; Ping-Chen Lin. 1999. A study on Investment Decision Making Model: Genetic Algorithms Approach Systems, Man, and Cybernetics, 1999. IEEE SMC '99 Conference Proceedings. 1999
- [125] IEEE International Conference on , Volume: 1 , 1999 Page(s): 1049 -1054 vol.1
- [126] Wing CH. A practical approach in implementing an expert support personal loan system. International Journal of Management; Poole; Sep 1997; Volume: 14, Issue 3
- [127] Wong F., Wang T. Quek B., 1992. Fuzzy Neural Systems for Stock Selection. Finanacial Analysis journal, January-February, 1992.
- [128] Yiu K., Komg A., 1992. Chossing the correct Expert System Development Method For Finanacial Decision-Making. Journal of Systems Management, Novemeber 1992.

## 9. APENDICES

### APENDICE A

Resultados de la corrida en SAS del Modelo propuesto por Speranza. Para el caso de 31 emisoras maximizando Rendimiento

```
The SAS System
OBS    ESPERO
1      .0005
```

L I N E A R P R O G R A M M I N G P R O C E D U R E

#### PROBLEM SUMMARY

Min obj	Objective Function
<u>_rhs_</u>	Rhs Variable
<u>_TYPE_</u>	Type Variable
Problem Density	0.121389

Variable Type	Number
Non-negative	126
Surplus	96
Total	222

Constraint Type	Number
EQ	1
GE	96
Objective	1
Total	98

The SAS System

L I N E A R   P R O G R A M M I N G   P R O C E D U R E

SOLUTION SUMMARY

Terminated Successfully  
 Objective value 0.145709

Phase 1 iterations	75
Phase 2 iterations	110
Phase 3 iterations	0
Integer iterations	0
Integer solutions	0
Initial basic feasible variables	97
Time used (secs)	1
Number of inversions	4

Machine epsilon	1E-8
Machine infinity	1.7976931349E308
Maximum phase 1 iterations	5000
Maximum phase 2 iterations	5000
Maximum phase 3 iterations	99999999
Maximum integer iterations	100
Time limit (secs)	12000

The SAS System

OBS	NOMBRE	AMOUNT	SUMA
1	x1	0.05416	0.05416
2	x12	0.03209	0.08626
3	x16	0.05070	0.13696
4	x17	0.04380	0.18076
5	x2	0.12465	0.30541
6	x20	0.00375	0.30916
7	x22	0.04578	0.35494
8	x24	0.01301	0.36795
9	x25	0.08390	0.45185
10	x27	0.04704	0.49889
11	x29	0.09353	0.59242
12	x30	0.13333	0.72574
13	x31	0.21981	0.94556
14	x4	0.05444	1.00000


## APÉNDICE B

Salida propuesta por el modelo de AG. Para el caso de 31 emisoras maximizando Rendimiento

Número de Generaciones:	200	Funcion de Aptitud: Rendimiento	Portafolios con Correlacion < .7
Tamaño de Población	180		
Tasa de Entrecruza(%)	90	Port-1	Correlaciones
Tasa de mutación(%)	0		
Número de Emisoras	31	televisa cpo	No existen Correlaciones
Número de Observaciones	9.60E+01	cifrac	
Función de Aptitud	0.00033436	masecab	
Tiempo	6.29	kimber a	
Var	0.00170058	ahmsa	
Rendimiento	0.00033436	gmodeloc	
	0	-0.00049147 livepol	
	1	-0.00049147 femsa	
	2	-0.00049147 comercialmex	
	3	-0.00049147 bachoco	
	4	-0.00049147 argos	
	5	-0.00049147 penoles	
	6	-0.00049147 Rendimiento	
	7	-0.00049147	0.00033436
	8	-0.00049147 Var	
	9	-0.00049147	0.00170058
	10	0.00033436 Rend/Var	
	11	0.00033436	0.19661488
	12	0.00033436	
	13	0.00033436	
	14	0.00033436	
	15	0.00033436	
	16	0.00033436	
	17	0.00033436	
	18	0.00033436	
	19	0.00033436	
	20	0.00033436	
	21	0.00033436	



22 0.00033436  
23 0.00033436  
24 0.00033436  
25 0.00033436  
26 0.00033436  
27 0.00033436  
28 0.00033436  
29 0.00033436  
30 0.00033436  
31 0.00033436  
32 0.00033436  
33 0.00033436  
34 0.00033436  
35 0.00033436



## APÉNDICE C

Resultados de la corrida en SAS del Modelo propuesto por Speranza. Para el caso de 149 emisoras maximizando Rendimiento

The SAS  
OBS      ESPERO

1      0.01

The SAS

L I N E A R   P R O G R A M M I N G   P R O C E D U R E

### PROBLEM SUMMARY

Min obj	Objective Function
_rhs_	Rhs Variable
_TYPE_	Type Variable
Problem Density	0.233562

Variable Type	Number
---------------	--------

Non-negative	236
Surplus	88

Total	324
-------	-----

Constraint Type	Number
-----------------	--------

EQ	1
GE	88
Objective	1

Total	90
-------	----

The SAS System

L I N E A R   P R O G R A M M I N G   P R O C E D U R E

### SOLUTION SUMMARY

Terminated Successfully

Objective value	0.049745
-----------------	----------

Phase 1 iterations	20
Phase 2 iterations	276
Phase 3 iterations	0
Integer iterations	0
Integer solutions	0
Initial basic feasible variables	89
Time used (secs)	0
Number of inversions	5

Machine epsilon	1E-8
Machine infinity	1.7976931349E308
Maximum phase 1 iterations	5000
Maximum phase 2 iterations	5000
Maximum phase 3 iterations	99999999
Maximum integer iterations	100
Time limit (secs)	12000

The SAS System			
OBS	NOMBRE	AMOUNT	SUMA
1	x106	0.04750	0.04750
2	x107	0.00202	0.04952
3	x111	0.06149	0.11101
4	x113	0.01351	0.12453
5	x12	0.00034	0.12487
6	x123	0.00019	0.12506
7	x13	0.03140	0.15645
8	x141	0.00034	0.15679
9	x142	0.01341	0.17020
10	x143	0.00884	0.17905
11	x17	0.01628	0.19533
12	x19	0.01223	0.20756
13	x22	0.03350	0.24105
14	x27	0.13010	0.37115
15	x32	0.01552	0.38667
16	x36	0.18375	0.57041
17	x47	0.00437	0.57478
18	x50	0.01529	0.59006
19	x52	0.01770	0.60776
20	x53	0.00052	0.60829
21	x54	0.04823	0.65651
22	x69	0.23778	0.89429
23	x72	0.00279	0.89709
24	x76	0.01166	0.90875
25	x78	0.00261	0.91136
26	x82	0.01385	0.92520
27	x91	0.04314	0.96834
28	x96	0.00451	0.97285
29	x97	0.01769	0.99055
30	x98	0.00945	1.00000


## APÉNDICE D

Salida propuesta por el modelo de AG. Para el caso de 149 emisoras maximizando Rendimiento

Número de Generaciones:	100	Funcion de Aptitud: Rendimiento		Portafolios con Correlacion < .6
Tamaño de Población	9094			
Tasa de Cruzamiento(%)	70	Port-1	Port-2	Correlaciones
Tasa de mutación(%)	0,01			
Número de Emisoras	149	accel s.a . B	america movil A	cemex cpo 0.60978403
Número de Observaciones	87	alfa sa A	apasco sa	Acemex cpo Wal Mart C 0.6422362
Función de Aptitud	0	almacenadora ACCE	ara	cemex cpo Wal mart V 0.60436021
Tiempo	3074.165	ALSEA	argos emb B	fomento econom mex ubd Wal mart V 0.61114294
Varianza	4.75825E-05	america movil A	bimbo gpo A	telmex LADR Wal Mart C 0.66391184
Rendimiento	0.001396358	apasco sa	comesa gpo ind	telmex LADR Wal mart V 0.69741072
	0	-0.001101305	argos emb B	Wal Mart C 0.85621172
	1	-0.001101305	asur aerop se B	
	2	-0.001101305	banamex accival gf o	
	3	-0.001101305	citygroup mexico	
	4	-0.001101305	collado sa	
	5	-0.001101305	corp interam de ent B	
	6	-0.001101305	cydsa sa A	
	7	-0.001101305	desc soc fom A	
	8	-0.001101305	desc soc fom B	
	9	-0.001101305	desc soc fom C	
	10	-0.001101305	dixon ticonderoga	
	11	-0.001101305	elektra gpo CPO	
	12	-0.001067671	far-ben B	
	13	-0.001067671	fomento econom mex ub	
	14	-0.001067671	fomento econom mex ubd	
	15	0.000812941	fragua corp B	
	16	0.000667336	Gcarso A1	
	17	0.00080935	gcorvi UBL	
	18	0.00080935	General de Seguros B	
	19	0.000924227	GF inbursa O	
	20	0.00083704	Gigante Gpo	
	21	0.00083704	Gmarti sa	
	22	0.00083704	Gmaseca(grupa) B	
	23	0.000939126	Gmex desarrollo B	
	24	0.000939126	Gmexico B	

25	0.000939126 Gpalacio de Hierro 1	inter de ceramica ADR
26	0.000939126 Gsamborns(com car) B	inter de ceramica UB
27	0.000689964 ICA soc Controlad ADR	invex gpo fin O
28	0.000689964 imsa gpo ADR	KOF coca cola femsa L
29	0.000959194 imsa gpo ubc	lamosa B
30	0.000641785 ind. Automotriz sa	maizoro sadecv
31	0.000641785 industrias CH B	maseca GIADR
32	0.000641785 inter de ceramica ADR	maseca GI B
33	0.000641785 invex gpo fin O	movil acces B
34	0.001282557 Kimbrly Clark Mex A	panamco
35	0.001039293 Kimbrly Clark Mex B	posadas A
36	0.000914031 KOF coca cola femsa L	posadas L
37	0.00083704 lamosa B	qumma B
38	0.00083704 liverpool 1	Radio centro ADR
39	0.000645308 maseca GIADR	saba casa ADR
40	0.000660907 maseca GI B	simec B
41	0.000660907 medica sur A	telmex LADR
42	0.000853824 movil acces B	televisa ADR
43	0.00090781 panamco	tvazteca CPO
44	0.00090781 parras A	tubos de acero
45	0.000848914 penoles	vitro A
46	0.000848914 pepsigx CPO	Wal Mart C
47	0.000715614 qumma B	Wal mart V
48	0.001102762 Radio centro ADR	wings B
49	0.001102762 Radio centro CPO	Rendimiento
50	0.001084679 saba casa	0.00139636
51	0.001193706 san luis Corp A	Var
52	0.001193706 simec ADR	4.7582E-05
53	0.00144822 sinkro A	Rend/Var
54	0.00144822 tekchem A	29.3460464
55	0.000813119 telmex AADR	
56	0.000813119 tvazteca ADR	
57	0.000813119 tmm AADR	
58	0.000813119 tubos de acero	
59	0.001091574 Valle jugos B	
60	0.001091574 vitro A	
61	0.001262585 Wal mart CADR	

62	0.001095434 wings B	
63	0.001546343 Rendimiento	
64	0.001557828	0.00128256
65	0.001557828 Var	
66	0.001557828	9.0016E-05
67	0.001179402 Rend/Var	
68	0.001130466	14.2481028
69	0.001070145	
70	0.001079817	
71	0.001079817	
72	0.001079817	
73	0.001120751	
74	0.001396358	
75	0.001462112	
76	0.001462112	
77	0.001630622	
78	0.001750645	
79	0.001321166	
80	0.001321166	
81	0.001321166	
82	0.001321166	
83	0.001284887	
84	0.001284887	
85	0.001284887	
86	0.0017245	
87	0.001260049	
88	0.001774326	
89	0.001774326	
90	0.001774326	
91	0.001433106	
92	0.001372311	
93	0.001805528	
94	0.001262585	
95	0.001328949	
96	0.001328949	
97	0.001616712	
98	0.001746517	




99	0.001396358
100	0.001396358

## APÉNDICE E

Salida propuesta por el modelo de AG. para el resultado de la corrida en SAS del Modelo propuesto por Speranza. Para el caso de 31 emisoras maximizando Rendimiento

Número de Generaciones: 2000	Funcion de Aptitud: Rendimiento	Portafolios con Correlacion < .
Tamaño de Población 102		
Tasa de Cruzamiento(%) 80	Port-1	Port-2
Tasa de mutación(%) 0.01		Correlaciones
Número de Emisoras 14	livepol	livepol
Número de Observaciones 96	moderna	argos
Función de Aptitud 0	argos	Rendimiento
Tiempo 33.311	Rendimiento	0.00264147Var
Varianza 0.00883069	0.00210446Var	0.00883069
Rendimiento 0.00440788 Var		0.0037256Rend/Var
	0 -0.00157475	0.00171851Rend/Var
	1 -0.00157475 Rend/Var	0.70900574
	2 -0.00157475	1.22458445
	3 -0.00157475	
	4 -0.00157475	
	5 -0.00157475	
	6 -0.00157475	
	7 -0.00157475	
	8 -0.00157475	
	9 -0.00157475	
	10 -0.00157475	
	11 -0.00157475	
	12 -0.00149464	
	13 -0.00149464	
	14 -0.00149464	
	15 -0.00149464	
	16 0.00210446	
	17 0.00210446	
	18 0.00210446	
	19 0.00210446	
	20 0.00210446	
	21 0.00210446	
	22 0.00210446	
	23 0.00210446	
	24 0.00210446	
	25 0.00210446	
	26 0.00210446	
	27 0.00210446	
	28 0.00210446	
	29 0.00210446	
	30 0.00210446	
	31 0.00210446	
	32 0.00210446	
	33 0.00210446	
	34 0.00210446	
	35 0.00210446	
	36 0.00210446	
	37 0.00210446	
	38 0.00210446	





39 0.00210446  
40 0.00210446  
41 0.00210446  
42 0.00210446  
43 0.00210446  
44 0.00210446  
45 0.00210446  
46 0.00210446  
47 0.00210446  
48 0.00210446  
49 0.00210446  
50 0.00210446  
51 0.00210446  
52 0.00210446  
53 0.00210446  
54 0.00210446  
55 0.00210446  
56 0.00210446  
57 0.00210446  
58 0.00210446  
59 0.00210446  
60 0.00210446  
61 0.00210446  
62 0.00210446  
63 0.00210446  
64 0.00210446  
65 0.00210446  
66 0.00210446  
67 0.00210446  
68 0.00210446  
69 0.00210446  
70 0.00210446  
71 0.00210446  
72 0.00210446  
73 0.00210446  
74 0.00210446  
75 0.00210446  
76 0.00210446  
77 0.00210446  
78 0.00210446  
79 0.00210446  
80 0.00210446  
81 0.00210446  
82 0.00210446  
83 0.00210446  
84 0.00210446  
85 0.00210446  
86 0.00210446  
87 0.00210446  
88 0.00210446  
89 0.00210446  
90 0.00210446  
91 0.00210446  
92 0.00210446  
93 0.00210446

94 0.00210446  
95 0.00210446  
96 0.00210446  
97 0.00210446  
98 0.00210446  
99 0.00105907  
100 0.00105907  
101 0.00210446  
102 0.00210446  
103 0.00210446  
104 0.00210446  
105 0.00210446  
106 0.00210446  
107 0.00210446  
108 0.00210446  
109 0.00210446  
110 0.00210446  
111 0.00210446  
112 0.00210446  
113 0.00210446  
114 0.00210446  
115 0.00192169  
116 0.00210446  
117 0.00210446  
118 0.00210446  
119 0.00210446  
120 0.00210446  
121 0.00210446  
122 0.00210446  
123 0.00210446  
124 0.00210446  
125 0.00210446  
126 0.00210446  
127 0.00210446  
128 0.00210446  
129 0.00210446

## APÉNDICE F

Resultados de la corrida en SAS del Modelo propuesto por Speranza para el resultado de la salida propuesta por el modelo de AG. Para el caso de 31 emisoras maximizando Rendimiento

```

The SAS System
OBS      ESPERO

          1      0.2
The SAS System
L I N E A R   P R O G R A M M I N G   P R O C E D U R E

      PROBLEM SUMMARY

Min obj                Objective Function
_rhs_                 Rhs Variable
_TYPE_               Type Variable
Problem Density      0.056944

Variable Type                Number

Non-negative                108
Surplus                      97

Total                        205

Constraint Type                Number

EQ                            1
GE                            97
Objective                      1

Total                          99

The SAS System
L I N E A R   P R O G R A M M I N G   P R O C E D U R E

      SOLUTION SUMMARY

Terminated Successfully

Objective value                0.561976

Phase 1 iterations             91
Phase 2 iterations             53
Phase 3 iterations             0
Integer iterations             0
Integer solutions              0
Initial basic feasible variables 98
Time used (secs)               0
Number of inversions           3

Machine epsilon                1E-8
Machine infinity               1.7976931349E308
Maximum phase 1 iterations     5000
Maximum phase 2 iterations     5000
Maximum phase 3 iterations     99999999
Maximum integer iterations     100
Time limit (secs)              12000
    
```

The SAS System

OBS	NOMBRE	AMOUNT	SUMA	
1	x11	0.27620	0.27620	argos
2	x12	0.13896	0.41516	peñoles
3	x3	0.16656	0.58172	maseca
4	x5	0.04958	0.63130	ahmsa
5	x7	0.36870	1.00000	liverpol


## APÉNDICE G

Salida propuesta por el modelo de AG. para el resultado de la corrida en SAS del Modelo propuesto por Speranza. Para el caso de 149 emisoras maximizando Rendimiento

Número de Generaciones: 700		Funcion de Aptitud: Rendimiento			Portafolios con Correlacion < .99		
Tamaño de Población	176						
Tasa de Cruzamiento(%)	70	Port-1	Port-2	Correlaciones	Port-4	Port-5	Port-6
Tasa de mutación(%)	0,01						
Número de Emisoras	30	pepsigx ADR	qumma B	No existen	Valle jugos B	pepsigx CPO	pepsigx ADR
Número de Observaciones	87	pepsigx CPO	cid mega resort	Correlaciones	valuegf o	qumma B	pepsigx CPO
Función de Aptitud	0	Radio centro CPO	unefon A	pepsigx CPO	banamex accival gf o	Radio centro CPO	Radio centro C
Tiempo	39.538	simec ADR	citygroup mexico	qumma B	bimbo gpo A	simec ADR	simec ADR
Varianza	0.258174632	valuegf o	ekco	simec ADR	unefon A	Valle jugos B	valuegf o
				valuegf o			
				banamex			
Rendimiento	0	0.05794037 banamex accival gf o	General de Seguros B	accival gf o	desc soc fom A	valuegf o	banamex acci
		0.001687431 unefon A	GFBanorte O	cid mega resort	GFBanorte O	bimbo gpo A	cid mega resor
				continental			
	1	0.001961925 desc soc fom A	Gpalacio de Hierro 1	grupo	GFBBVBancomer O	cid mega resort	unefon A
	2	0.002181249 ekco	KOF coca cola femsa L	desc soc fom A	GFBBital L	unefon A	continental gru
	3	0.003212693 General de Seguros B	maseca GI B	ekco	Gpalacio de Hierro 1	continental grupo	cydsa sa A
	4	0.00452284 ICA soc Controlad ADR	medica sur A	gcorvi UBL	imsa gpo ubc	cydsa sa A	desc soc fom
				General de			
	5	0.004559689 inter de ceramica UB	Rendimiento	Seguros B	inter de ceramica UB	desc soc fom A	ekco
	6	0.004559689 maseca GIADR		GFBanorte O	Rendimiento	ekco	gcorvi UBL
				Gpalacio de			
	7	0.004559689 maseca GI B	Var	Hierro 1		0.00321269gcorvi UBL	General de Se
				Hilsal mexicana		General de	
	8	0.005651909 medica sur A		A	Var	Seguros B	GFBBVBanco
	9	0.005651909 Rendimiento	Rend/Var	maseca GI B		GFBanorte O	GFBBital L
	10	0.005651909	0.00168743	14.2247947Rendimiento	Rend/Var	GFBBital L	Gpalacio de Hi
						Gpalacio de Hierro	
	11	0.005651909 Var			0.002181249	66.09394311	Hilsal mexican
	12	0.005994361	-4.0641E-05		Var	Hilsal mexicana A	imsa gpo ubc
						ICA soc Controlad	
	13	0.005994361 Rend/Var			8.5958E-05	ADR	inter de cerami
	14	0.006120567	-41.5207189		Rend/Var	imsa gpo ubc	KOF coca cola
						inter de ceramica	
	15	0.006120567			25.3757634	UB	maseca GIAD

16 0.006120567  
 17 0.006261699  
 18 0.006261699  
 19 0.006654129  
 20 0.006654129  
 21 0.006565295  
 22 0.006654129  
 23 0.006654129  
 24 0.006654129  
 25 0.006258331  
 26 0.006654129  
 27 0.006654129  
 28 0.006654129  
 29 0.006654129  
 30 0.006461358  
 31 0.006654129  
 32 0.006654129  
 33 0.006654129  
 34 0.006654129  
 35 0.006654129  
 36 0.006654129  
 37 0.007131277  
 38 0.007131277  
 39 0.00750929  
 40 0.007557182  
 41 0.007557182  
 42 0.007557182  
 43 0.007557182  
 44 0.006827498  
 45 0.006827498  
 46 0.006827498  
 47 0.006827498  
 48 0.007711743  
 49 0.007711743  
 50 0.008572646  
 51 0.008572646

KOF coca cola  
 femsa L                   medica sur A  
 maseca GIADR           Rendimiento  
 maseca GI B  
 medica sur A            Var  
 Rendimiento  
                               0.00452284Rend/Var  
 Var  
                               0.0003891  
 Rend/Var  
                               11.6237701



52	0.008572646
53	0.008572646
54	0.008572646
55	0.008572646
56	0.008572646
57	0.008572646
58	0.008572646
59	0.00258451
60	0.011301362
61	0.011301362
62	0.010813273
63	0.011670687
64	0.011670687
65	0.010813273
66	0.011670687
67	0.011098548
68	0.013655682
69	0.013655682
70	0.011862888

### APÉNDICE G (continuación)

Port-7	Port-8	Port-9	Port-10	Port-11	Port-12	Port-13	Port-14
pepsigx ADR	simec ADR	pepsigx CPO	pepsigx CPO	qumma B	cid mega resort	pepsigx CPO Radio centro	pepsigx CPO
pepsigx CPO	valuegf o	qumma B	Valle jugos B	valuegf o	unefon A citygroup	CPO	qumma B
qumma B	bimbo gpo A	Radio centro CPO	valuegf o banamex accival gf	bimbo gpo A	mexico continental	bimbo gpo A	Valle jugos B
Radio centro CPO valuegf o cid mega resort citygroup mexico cydsa sa A	cid mega resort unefon A cydsa sa A ekco General de Seguros B	banamex accival gf o unefon A citygroup mexico continental grupo cydsa sa A	banamex accival gf o bimbo gpo A cydsa sa A desc soc fom A ekco General de Seguros B	cid mega resort continental grupo cydsa sa A desc soc fom A ekco	grupo cydsa sa A ekco gcorvi UBL GFBital L ICA soc Controlad ADR	citygroup mexico continental grupo cydsa sa A desc soc fom A GFBanorte O GFBanorte O	valuegf o citygroup mexico cydsa sa A ekco Hilsal mexicana A ICA soc Controlad ADR
gcorvi UBL General de Seguros B	ICA soc Controlad ADR imsa gpo ubc	ekco gcorvi UBL	Seguros B Hilsal mexicana A ICA soc Controlad ADR	gcorvi UBL GFBanorte O GFBanorte O	Controlad ADR maseca GIADR	O GFBital L	ICA soc Controlad ADR imsa gpo ubc
GFBanorte O	KOF coca cola femsa L	GFBanorte O	inter de ceramica UB KOF coca cola femsa L	GFBital L ICA soc Controlad ADR	maseca GI B Rendimiento	Hilsal mexicana A KOF coca cola femsa L	maseca GIADR maseca GI B
Gpalacio de Hierro 1	maseca GIADR	GFBanorte O	UB KOF coca cola femsa L	GFBital L ICA soc Controlad ADR	0.007131277 Var	maseca GIADR Rendimiento	Rendimiento
Hilsal mexicana A maseca GIADR	maseca GI B medica sur A	Hilsal mexicana A inter de ceramica UB	maseca GIADR	imsa gpo ubc inter de ceramica UB	0.00224665 Rend/Var	0.00750929 Var	Var
maseca GI B medica sur A Rendimiento	Rendimiento Var	medica sur A Rendimiento	medica sur A Rendimiento	maseca GIADR maseca GI B	0.00224665 3.174183305	0.00750929 Var	0.00599436 0.00138517
0.00565191	0.00138517	0.00612057	0.0062617	Rendimiento	0.00224665	0.00750929	0.00152185
Var	Rend/Var	0.00116915	0.00115265	0.00665413	3.174183305	0.00152185	Rend/Var
0.00102863	4.32754068	Rend/Var	Rend/Var	Var	3.174183305	0.00152185	4.93433294
Rend/Var	5.49462212	5.23507308	5.43242204	0.00095404	3.174183305	0.00152185	Rend/Var
				Rend/Var	3.174183305	0.00152185	Rend/Var
				6.97467193			



### APÉNDICE G (continuación)

Port-15	Port-16	Port-17	Port-18	Port-19	Port-20	Port-21	Port-22	Port-23	Port-24
pepsigx ADR	pepsigx CPO	pepsigx CPO	pepsigx CPO	pepsigx CPO	simec ADR	simec ADR	simec ADR	simec ADR	cydsa sa A
pepsigx CPO	simec ADR	Radio centro CPO	simec ADR	simec ADR	cydsa sa A	Valle jugos B	bimbo gpo A	cydsa sa A	gcorvi UBL
bimbo gpo A	cydsa sa A	simec ADR	cydsa sa A	cydsa sa A	gcorvi UBL	cydsa sa A	cydsa sa A	GFBital L	GFBital L
continental grupo	gcorvi UBL	cydsa sa A	desc soc fom A	gcorvi UBL	GFBital L	GFBital L	GFBital L	Rendimiento	Rendimiento
cydsa sa A	General de Seguros B	gcorvi UBL	gcorvi UBL	GFBital L	Rendimiento	Rendimiento	Rendimiento	0.02182614	0.02194531
ekco	Gpalacio de Hierro 1	GFBital L	GFBital L	Rendimiento	0.01685604	0.0172169	0.01794646	Var	Var
GFBanorte O	ICA soc Controlad ADR	Rendimiento	Rendimiento	0.01365568	Var	Var	Var	0.02871826	0.02862181
GFBVBancomer O	maseca GIADR	0.01130136	0.0116706	Var	0.01614971	0.0160556	0.01616429	Rend/Var	Rend/Var
GFBital L	maseca GI B	Var	Var	0.0103712	Rend/Var	Rend/Var	Rend/Var	0.76000903	0.76673382
Gpalacio de Hierro 1	Rendimiento	0.00689369	0.0072009	Rend/Var	1.04373632	1.07232983	1.11025377		
ICA soc Controlad ADR		0.00857265	Rend/Var	Rend/Var	1.31669195				
inter de ceramica UB	Var		1.63937734	1.6207054					
maseca GIADR		0.00316127							
Rendimiento	Rend/Var								
	0.00771174	2.71177515							
Var									
	0.00155626								
Rend/Var									
	4.955306								
Port-25	Port-26	Port-27							
cydsa sa A	cydsa sa A	cydsa sa A							
GFBital L	GFBital L	Rendimiento							
imsa gpo ubc	Rendimiento	0.05794037							
Rendimiento	0.03194509	Var							
	0.02242686	Var							
		0.25817463							
Var	0.06441632	Rend/Var							
	0.02862701	Rend/Var							
		0.22442317							
Rend/Var	0.49591615								
		0.78341591							

## APÉNDICE H

Resultados de la corrida en SAS del Modelo propuesto por Speranza para el resultado de la salida propuesta por el modelo de AG. Para el caso de 149 emisoras maximizando Rendimiento

The SAS System  
OBS      ESPERO  
  
1      .007  
The SAS System

L I N E A R   P R O G R A M M I N G   P R O C E D U R E

### PROBLEM SUMMARY

Min obj	Objective Function
<u>_rhs_</u>	Rhs Variable
<u>_TYPE_</u>	Type Variable
Problem Density	0.14426
Variable Type	Number
Non-negative	142
Surplus	88
Total	230
Constraint Type	Number
EQ	1
GE	88
Objective	1
Total	90

The SAS System

L I N E A R   P R O G R A M M I N G   P R O C E D U R E

### SOLUTION SUMMARY

Terminated Successfully

Objective value	0.258426
Phase 1 iterations	82
Phase 2 iterations	52
Phase 3 iterations	0
Integer iterations	0
Integer solutions	0
Initial basic feasible variables	89
Time used (secs)	0
Number of inversions	3
Machine epsilon	1E-8
Machine infinity	1.7976931349E308
Maximum phase 1 iterations	5000
Maximum phase 2 iterations	5000
Maximum phase 3 iterations	99999999
Maximum integer iterations	100
Time limit (secs)	12000

The SAS System				
OBS	NOMBRE	AMOUNT	SUMA	
1	x23	0.39200	0.39200	GFBBVBancomer
2	x24	0.21171	0.60371	GFBitall L
3	x33	0.01125	0.61495	inter de cerámica UB
4	x39	0.03367	0.64862	Maseca GIB
5	x44	0.07422	0.72284	quma B
6	x5	0.27716	1.00000	bimbo gpo A

## **10. Descripción De La Aplicación: PortAlGe**

### **10. 1 Requerimientos de la aplicación**

Los requerimientos mínimos para que la aplicación PortAlGe tenga un buen desempeño son los siguientes:

- Computadora PC Pentium III con 124 Kb de memoria RAM
- Disco duro 1 Gb
- Windos 95
- Microsoft Excel 2000

### **10. 2 Como cargar la aplicación:**

La aplicación esta contenida en el archivo PortAlGe.xls (archivo de excel 2000). Se recomienda que una vez cargado dicho archivo y antes de iniciar su uso, se haga una copia del mismo (Menú: Archivo, Grabar como...) y se trabaje sobre esta copia, con el fin de tener siempre el original intacto.

La aplicación consta de cuatro hojas, las cuales de describen a continuación:

### **10.3 Hoja de datos:**

Esta hoja contiene los datos de los rendimientos de las emisoras, se ingresan en la columna A, las fechas de los rendimientos comenzando con la celda A2 hacia abajo, las emisoras se ingresan en las columnas siguientes, el encabezado de cada emisora en las celadas B1, C1, .... Etc., y los rendimientos correspondientes a cada fecha en la columna de cada emisora. Fig. 10.1.

La celda A1 debe estar Vacía. Al termino de la captura o copiado de los rendimientos debe existir al menos una columna en blanco para el caso de

las emisoras y al menos una hilera en blanco para el caso de las fechas u observaciones de todas las emisoras, si se respetan estas normas la aplicación detecta automáticamente cuantas emisoras y cuantas observaciones se capturaron.

	A	B	C	D	E	F
1		tvaztecacpo	televisa cpo	cemexa	cifrac	qiganteb
2	01/07/1998	0.012711864406780	-0.006250034659091	0.000000000000000	-0.021739109512558	0.01657
3	02/07/1998	0.025104602510460	0.003430566729139	0.042857142857143	0.012898400250945	-0.0217E
4	03/07/1998	-0.004081632653061	-0.014814849572650	-0.017808260986301	-0.028213213443509	0.0000C
5	06/07/1998	-0.032786885245902	0.020821319994275	0.032078147139505	0.048387128986734	-0.02777
6	07/07/1998	0.000000000000000	0.013597699150142	0.008108087486487	0.053846139153846	0.0142E
7	08/07/1998	-0.004237288135593	0.006707726332684	0.000000000000000	0.004379592761788	0.0000C
8	09/07/1998	-0.029787234042553	0.007773425055981	0.018766776871824	-0.015988391231007	0.0000C
9	10/07/1998	-0.048245614035088	0.008264462809917	0.007894716763158	-0.00738552605661	0.0000C
10	13/07/1998	-0.036866359447005	0.010928961748634	0.018276782687864	-0.004464246121651	0.0000C
11	14/07/1998	-0.014354066985646	-0.000540573513514	0.017948737512821	-0.028400606185525	-0.0112E
12	15/07/1998	0.000000000000000	0.010275874595364	-0.025188916392465	-0.013846177307692	-0.0313E
13	16/07/1998	-0.024271844660194	0.003211942399377	0.000000000000000	0.057722366817888	0.0205E
14	17/07/1998	-0.029850746268857	-0.012806798175675	0.000000000000000	-0.004424809597462	-0.02017
15	20/07/1998	0.015384615384615	0.010810810810811	0.000000000000000	0.000000000000000	0.0000C
16	21/07/1998	0.080808080808081	-0.005347593582888	-0.038759689158304	-0.007407435629630	0.0000C
17	22/07/1998	-0.046728971962617	-0.005376344086022	-0.012096794456187	0.000000000000000	0.0000C
18	23/07/1998	-0.009803921568627	0.000000000000000	-0.001360523455782	0.007462715212186	0.0000C
19	24/07/1998	-0.024752475247525	-0.016216216216216	-0.020435966877585	-0.004444475555556	0.0000C
20	27/07/1998	-0.035532994923858	-0.171428554670330	-0.027816411092520	-0.002976187667411	0.0235E
21	28/07/1998	-0.068421052631579	0.014588838895916	-0.015736744634989	0.022388003472375	-0.0229E
22	29/07/1998	-0.033898305084746	0.019607843137255	0.002906932254768	0.025954136573395	-0.0117E
23	30/07/1998	-0.017543859649123	-0.002564063461538	-0.040579754376812	-0.032738065011160	-0.0238C
24	31/07/1998	-0.083333333333333	-0.002570752791249	-0.018126842950501	-0.007692337000000	-0.0243E
25	03/08/1998	-0.038961038961039	-0.030283486097710	-0.016923053446154	-0.007751893872362	-0.0124E
26	04/08/1998	0.027027027027027	-0.049833887043189	0.014084530586964	0.000000000000000	-0.0189E
27	05/08/1998	-0.026315789473684	-0.031468531468532	-0.033951686333333	-0.007812529777172	-0.0129E

Fig. 10. 1 Hoja de Datos

#### 10.4 Hoja de Covarianza

En esta hoja se guardará la matriz de varianzas y covarianzas de los rendimientos de la Hoja de Datos. Esta Hoja es un subproducto de la aplicación, ya que se utiliza para los cálculos del VaR. Esta hoja se pone a disposición del usuario para sus propias consultas. Fig. 10.2.

	A	B	C	D	E	F	G	H	I	J
1										
2	Columna 1	Columna 2	Columna 3	Columna 4	Columna 5	Columna 6	Columna 7	Columna 8	Columna 9	Columna 10
3	Columna 2	-0.00014512	0.00257559	0.00121943	0.00084407	0.00063682	0.0014423	0.00076565	0.00119624	0.00
4	Columna 3	1.2058E-05	0.00121943	0.00203407	0.00090044	0.00064349	0.00176815	0.00077922	0.00094548	0.00
5	Columna 4	0.00023997	0.00084407	0.00090044	0.0013751	0.00047886	0.00132889	0.00061286	0.00064804	0.00
6	Columna 5	2.0286E-05	0.00063682	0.00064349	0.00047886	0.00105864	0.0006439	0.00042511	0.00051876	0.00
7	Columna 6	0.00086496	0.0014423	0.00176815	0.00132889	0.0006439	0.0036795	0.00104608	0.00104081	0.00
8	Columna 7	0.00034539	0.00076565	0.00077922	0.00061286	0.00042511	0.00104608	0.00106802	0.00051886	0.00
9	Columna 8	0.00015775	0.00119624	0.00094548	0.00064804	0.00051876	0.00104081	0.00051886	0.00160316	0.00
10	Columna 9	0.00011828	0.00101993	0.00106865	0.00087485	0.00045459	0.00145263	0.00057738	0.00061525	0.00
11	Columna 10	-0.00018578	0.00057469	0.00044223	0.00037815	0.00014937	0.00038941	0.00020675	0.00063842	0.0
12	Columna 11	0.00046476	0.00028045	0.00024354	0.00028724	3.6154E-05	0.00080955	0.00017608	0.00011004	0.00
13	Columna 12	0.00113861	0.00179212	0.00180141	0.00117016	0.0011635	0.00232497	0.0011652	0.00135852	0.00
14	Columna 13	-1.6974E-05	0.00065403	0.00083203	0.00059208	0.00043687	0.00077607	0.00048374	0.00050061	0.0
15	Columna 14	-0.0002141	0.0007725	0.00053434	0.00061285	0.000544	0.00057586	0.00037628	0.00066541	0.00
16	Columna 15	0.00037871	0.00106294	0.00110283	0.00114036	0.00054494	0.00185747	0.0008878	0.0005776	0.00
17	Columna 16	0.000243	0.00036005	0.00055624	0.00048032	0.0003512	0.00042732	0.00030764	0.00032892	0.00
18	Columna 17	0.00073386	0.00151662	0.00147442	0.00132769	0.00079853	0.00265307	0.0011327	0.00126685	0.00
19	Columna 18	5.2952E-06	0.00123066	0.00121147	0.00099649	0.00068152	0.00150144	0.00076556	0.00100227	0.00
20	Columna 19	0.00100464	0.00041925	0.00012311	0.00025068	0.00013239	0.00051924	0.00031835	0.00021572	0.00
21	Columna 20	0.00094789	0.00087522	0.0010271	0.0008326	0.00030031	0.0013912	0.0006319	0.00063585	0.0
22	Columna 21	0.00051315	0.00100624	0.00090475	0.00065593	0.00034691	0.00150337	0.00057012	0.00064813	0.00
23	Columna 22	0.00024805	0.00092472	0.00111018	0.00094338	0.00063805	0.00145915	0.00064121	0.00059229	0.00
24	Columna 23	2.0286E-05	0.00063682	0.00064349	0.00047886	0.00105864	0.0006439	0.00042511	0.00051876	0.00
25	Columna 24	8.5042E-06	0.00109272	0.00118275	0.00078817	0.00055493	0.00140947	0.00070275	0.00074232	0.00
26	Columna 25	0.00020315	0.00043443	0.00041617	0.00045233	0.00015984	0.00054756	0.00030551	0.00042757	0.0
27	Columna 26	0.00043796	0.00100071	0.00093144	0.00090582	0.00043286	0.00148401	0.00069624	0.00064884	0.00

Fig.10.2 Hoja de Covarianzas

### 10.5 Hoja de Correlaciones

Esta Hoja, al igual que la de Covarianza , es otro subproducto de la aplicación, y es utilizada para verificar las correlaciones entre emisoras. También se pone a disposición del usuario para consultas propias. Fig.10.3.

Microsoft Excel - GAEXCEL.xls

Archivo Edición Ver Insertar Formato Herramientas Datos Ventana Z

Seguridad... Σ 100%

B8 = 0.178264630634653

	A	B	C	D	E	F	G	H	I	J
1		lvaztecacpo	televisa cpo	cemexa	cifrac	giganteb	elektra cpo	masecab	kofl	kimt
2	lvaztecacpo	1								
3	televisa cpo	-0.04823335	1							
4	cemexa	0.00450965	0.53276507	1						
5	cifrac	0.10915192	0.44851341	0.53840133	1					
6	giganteb	0.01051652	0.38565704	0.43851691	0.39689181	1				
7	elektra cpo	0.24051603	0.46851524	0.64631099	0.5907835	0.32625179	1			
8	masecab	0.17826463	0.4616384	0.52867264	0.50571117	0.39979489	0.52769055	1		
9	kofl	0.06645481	0.58869691	0.52357992	0.43646076	0.3981995	0.42853709	0.39652665	1	
10	kimber a	0.0511207	0.51494825	0.60713459	0.60450576	0.35799711	0.6136081	0.45269479	0.39372613	1
11	ahmsa	-0.0871197	0.31482929	0.27261189	0.28351188	0.12763976	0.17847923	0.17588426	0.44329653	0.2
12	dina	0.14421925	0.10166324	0.09934205	0.14250455	0.02044216	0.24552409	0.0991188	0.05055825	0.1
13	hilasal	0.23338039	0.42911358	0.48537046	0.38346097	0.43454741	0.46576499	0.43326498	0.41230785	0.4
14	bimbo	-0.00792256	0.35661427	0.51050095	0.44183334	0.37155038	0.35403826	0.40960042	0.34598135	0.5
15	gmodeloc	-0.10397308	0.43571508	0.33913557	0.4730775	0.47859315	0.27174534	0.32958263	0.47570984	0.4
16	ica	0.12272422	0.40239471	0.46979331	0.5908213	0.32177775	0.58831428	0.52192338	0.27715282	0.4
17	livepol	0.13026733	0.22547657	0.39197609	0.41166443	0.34305168	0.22389319	0.2991835	0.26108652	0.3
18	femsa	0.1955745	0.47216376	0.51652686	0.56570004	0.3877683	0.69104965	0.54761954	0.49991074	0.6
19	gcarso	0.00208216	0.56531084	0.62620723	0.62646239	0.48830475	0.57703381	0.54610481	0.58355842	0.5
20	dataflux	0.3427307	0.16708266	0.05520918	0.13672419	0.08229565	0.17312976	0.19702165	0.10896603	0.2
21	biper	0.26585964	0.28676813	0.37869028	0.37335769	0.15347684	0.38137055	0.32152425	0.26406842	0.5
22	apasco	0.21639852	0.49570658	0.50154096	0.57707717	0.26656542	0.61963204	0.43615521	0.40470348	0.5
23	soriana	0.10597227	0.46151527	0.62348127	0.64436737	0.49669881	0.60928687	0.49696107	0.37468155	0.6
24	gigante	0.01051652	0.38565704	0.43851691	0.39689181	1	0.32625179	0.39979489	0.3981995	0.3
25	comercialmex	0.00371992	0.55837695	0.68009504	0.55119991	0.44230692	0.60258729	0.55766052	0.48079635	0.5
26	sigma	0.1110478	0.27740935	0.29904189	0.39530417	0.15920429	0.29253563	0.30295569	0.34606521	0.3
27	maizorro	0.1599443	0.43386308	0.45441632	0.53747365	0.29272262	0.53830323	0.4887615	0.36555777	0.5

Datos Covarianza Correlacion Resultados

Listo

Fig.10.3. Hoja de Correlaciones.

## 10.6 Hoja de resultados

En esta se muestran los resultados del AG. Presenta la siguiente información:

- Número de Generaciones
- Tamaño de Población
- Tasa de entrecruza (%)
- Tasa de mutación(%)
- Número de emisoras
- Número de observaciones
- Función de Aptitud
- Tiempo de ejecución
- Varianza
- Rendimiento

Presenta el ó los (según el caso) portafolios encontrados según la función de aptitud seleccionada con ó sin (según el caso) su correlaciones.

Además muestra una gráfica de la evolución de la Función de Aptitud en cada generación. Fig.10. 4.

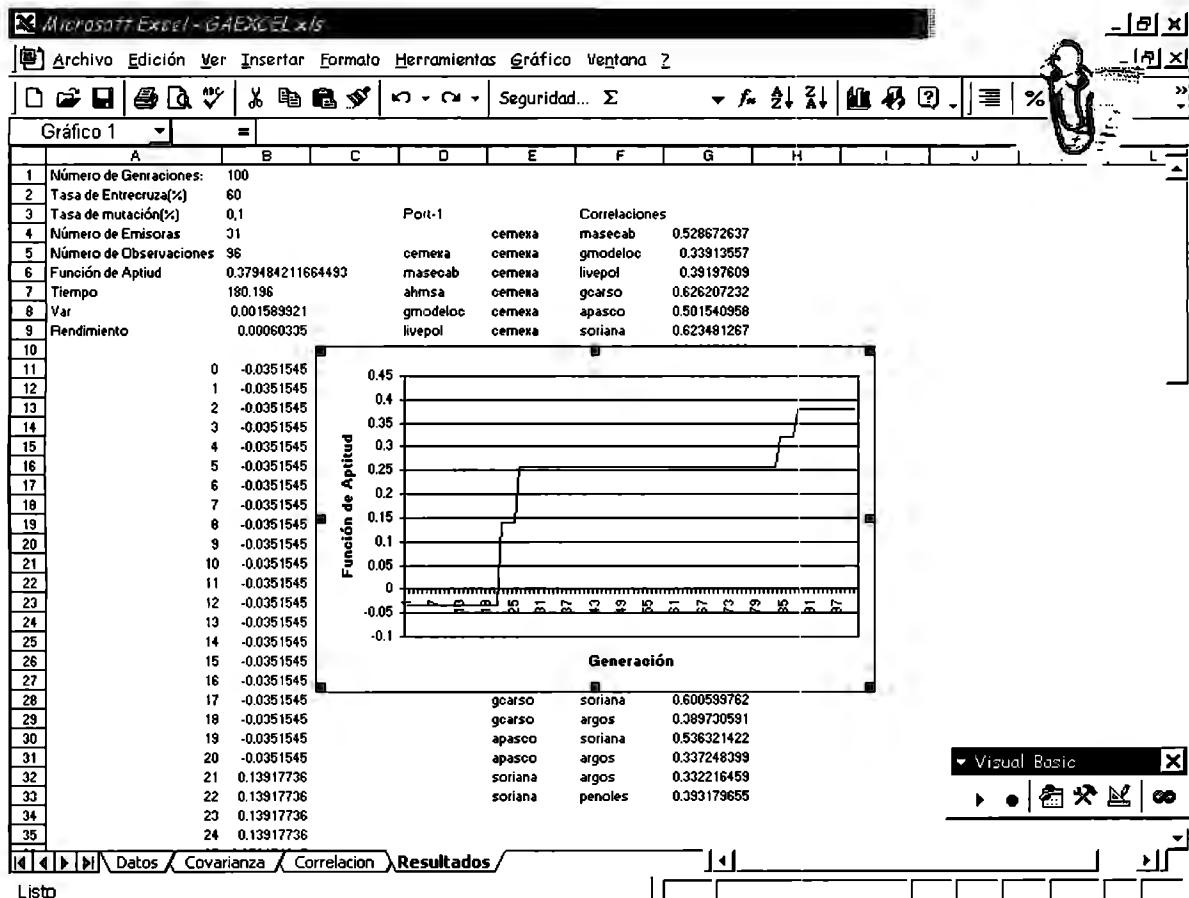


Fig. 10.4. Hoja de Resultados.

### 10.7 Para iniciar la aplicación

Una vez cargados los datos de rendimientos en la Hoja de datos, se presiona simultáneamente las teclas Ctrl y p, esta acción presentará la ventana de parámetros sobre la Hoja de datos, Fig. 10.5.



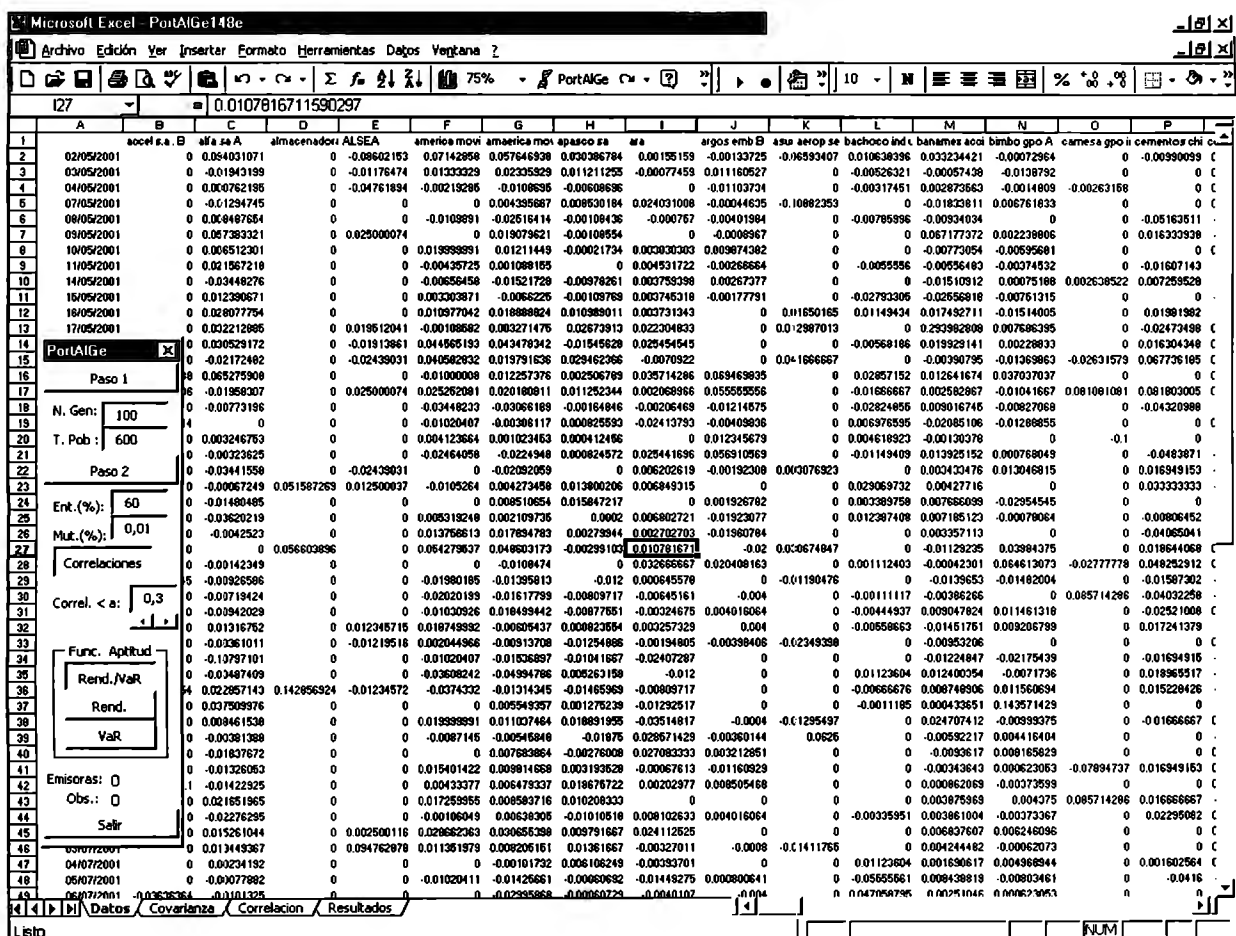


Fig. 10.5. Ventana de parámetros

Esta ventana permitirá al usuario modificar los parámetros principales de la aplicación como se observa en la Fig. 10.6.

Los parámetros que son susceptibles a modificación son:

- **Número de Generaciones:** Modifica el número de generaciones que el AG trabajará.
- **Tamaño de Población :** Modifica el tamaño de población con las que el AG trabajará.
- **Tasa de entrecruza (%):** Modifica la tasa de entrecruza que se aplicará al AG.
- **Tasa de mutación(%):** Modifica la tasa de mutación que se aplicará al AG.
- **Correlaciones:** Indica al AG mostrar las correlaciones que el portafolio seleccionado tiene .

- Correlaciones menores a: Permite al usuario indicar la correlación máxima para selección del portafolio.
- Funciones de Aptitud: Permite al usuario seleccionar entre tres posibles funciones de aptitud:
  - Rendimiento/Varianza
  - Rendimiento
  - Varianza

The screenshot shows a window titled "PortAIge" with a close button (X). It is divided into two sections: "Paso 1" and "Paso 2".

**Paso 1:**

- N. Gen: 100
- T. Pob.: 600

**Paso 2:**

- Ent. (%): 60
- Mut. (%): 0,01
- Correlaciones:
  - Correl. < a: 0,3
- Func. Aptitud:
  - Rend./VaR (selected)
  - Rend.
  - VaR.
- Emisoras: 0
- Obs.: 0
- Salir

Fig. 10.6. Ventana de Parámetros

Para iniciar el trabajo de la aplicación es necesario dar clic en el botón de **Paso 1**, esto permitirá a la aplicación realizar los cálculos iniciales y sugerir un tamaño de población; el usuario puede cambiar el tamaño de la población sugerido, y el número de Generaciones con las que el AG trabajará si lo desea.

A continuación se da clic en el botón de **Paso 2** para dar inicio al AG.

La ventana de parámetros estará presente durante todo el proceso de cálculo y presentación de resultados, para tener acceso a la Hoja de Resultados es necesario dar clic en la hoja de cálculo.

Si se desea modificar los parámetros se da clic en la ventana de parámetros y se modifican. Para continuar es necesario dar clic el botón de **Paso 2** . El Botón de Paso 1 solo se utiliza al inicio de la sesión ( con un conjunto de datos) o cuando se quiera que se calcule el tamaño de población.

Para finalizar la sesión de trabajo se da clic en el botón de **Salir**.