



UNIVERSIDAD NACIONAL AUTONOMA  
DE MEXICO

FACULTAD DE INGENIERIA

DISEÑO DE UN MANEJADOR DE ARCHIVOS  
DE ACCESO DIRECTO POR MULTIPLES  
LLAVES

T E S I S

QUE PARA OBTENER EL TITULO DE  
INGENIERO EN COMPUTACION

P R E S E N T A N :

JAVIER RIVERA CHAVEZ  
HECTOR CONRADO JIMENEZ SILVA

DIRECTOR DE TESIS  
ING. LUIS G. CORDERO BORBOA.



MEXICO, D.F.

ABRIL 1991

FALLA DE ORIGEN



Universidad Nacional  
Autónoma de México



## **UNAM – Dirección General de Bibliotecas Tesis Digitales Restricciones de uso**

### **DERECHOS RESERVADOS © PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL**

Todo el material contenido en esta tesis está protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

# TESIS CON FALLA DE ORIGEN

# DISEÑO DE UN MANEJADOR DE ARCHIVOS DE ACCESO DIRECTO

## POR MÚLTIPLES CLAVES

### INDICE

INTRODUCCION	3
1 DESCRIPCION DE ARCHIVOS TRADICIONALES	7
1.1 Archivos secuenciales	7
1.2 Archivos secuenciales indexados	11
1.3 Archivos directos	16
2 DISEÑO DE LAS ESTRUCTURAS DE DATOS	26
2.1 Descripción de las estructuras de datos tradicionales	26
2.1.1 Estructuras de datos lineales	27
2.1.2 Estructuras de datos no lineales	31
2.2 Diseño de las estructuras de datos	35
2.3 Ventajas de las estructuras de datos diseñadas	37
3 DISEÑO DE LA FUNCIÓN DE DISPERSIÓN Y DE LA RESOLUCIÓN DE COLISIONES	39
3.1 Descripción de las funciones de dispersión tradicionales	39
3.1.1 Métodos de dispersión de distribución independiente	40
3.1.2 Métodos de dispersión de distribución dependiente	43
3.1.3 Métodos de dispersión dinámica	45
3.2 Diseño del algoritmo de dispersión	47
3.3 Descripción de los métodos de resolución de colisiones tradicionales	49

3.3.1	Métodos de direccionamiento abierto	50
3.3.2	Métodos de direccionamiento	50
3.4	Diseño del algoritmo de resolución de colisiones	51
4	SIMULACION DEL MANEJADOR DE ARCHIVOS	55
4.1	Desarrollo del manejador de archivos	57
4.2	Demstración de resultados	63
	CONCLUSIONES	102
	APLICACIONES	110
	BIBLIOGRAFIA	117

## INTRODUCCION

Se entiende por informática, palabra formada por la abstracción de los términos INFORMACIÓN y AUTOMÁTICA, el conjunto de métodos y técnicas que tienen como objetivo el tratamiento racional y automático de la información. La informática nació cuando el hombre sintió la necesidad de almacenar y ordenar los múltiples conocimientos heredados de sus antepasados para tenerlos a su alcance y utilizarlos a su debido tiempo. La computadora, máquina destinada a procesar los datos, ha llegado a liberar de los trabajos puramente mecánicos y rutinarios al ser humano que, de este modo, tiene la posibilidad de dedicarse a tareas más útiles y creativas. Las empresas, grandes y pequeñas, se esfuerzan por disponer de computadoras. En la actualidad, ningún Estado, aunque carezca de medios, puede prescindir de esta nueva técnica ya que la potencia económica de un país depende en gran parte de ella.

El desarrollo informático en nuestro país en los últimos años ha venido en creciente aumento lo cual es originado por la gran necesidad que existe en todas las áreas de tener un alto nivel de automatización, aunado a la relativa facilidad con que se puede disponer de recursos de cómputo.

Uno de los principales usuarios de los recursos de cómputo de reciente tecnología son las instituciones bancarias las que han procurado mantenerse actualizadas con sistemas de cómputo de nueva tecnología, buscando siempre como finalidad ofrecer a sus clientes mejores servicios automatizados.

En la actualidad la rapidez con que una institución pueda reaccionar a desarrollar un nuevo sistema es muy importante, ya que los cambios constantes en el mercado de dinero hacen necesario tener una rápida respuesta de las áreas de desarrollo de sistemas.

Para todos es sabido que el desarrollo de los programas es más lento que el desarrollo de los equipos. Siendo esto una preocupación para las firmas constructoras de computadores. Es por esto que se han desarrollado lenguajes de cuarta generación tales como bases de datos, generadores de aplicaciones etc., los cuales contribuyen en gran medida a aprovechar eficientemente los recursos humanos.

Sin embargo no todos los usuarios de computadores tienen una infraestructura de desarrollo de sistemas que incluya herramientas modernas de desarrollo que les permita lograr estos resultados. En la actualidad con tantas marcas de computadores y capacidades de los mismos, es difícil establecer una estrategia de desarrollo informática global.

Esto representa en general una gran desventaja para algunas empresas que no han definido una línea de desarrollo. La cual les obliga a renovar sus equipos de cómputo con una frecuencia aproximada de cinco años sin riesgo de caer en la obsolescencia.

Estos cambios en muchas ocasiones representan un retroceso en cuanto a automatización de sistemas se refiere, debido a que en estas ocasiones es necesario asignar los viejos sistemas a los equipos nuevos perdiéndose valiosas horas de trabajo.

Esta situación obliga a la institución a exigir esfuerzos extras en su personal para salir a tiempo al mercado con un producto nuevo y en algunas ocasiones con posterioridad a la de las instituciones líderes en la banda nacional.

Una computadora es una máquina que puede resolver problemas ejecutando unas instrucciones dadas. Se llama programa a una secuencia de instrucciones que describe como ejecutar cierta tarea. Los circuitos electrónicos de cada computadora pueden reconocer y ejecutar directamente un conjunto limitado de instrucciones simples. Todos los programas que se deseen ejecutar en una computadora deben convertirse previamente en una secuencia de estas instrucciones simples. Estas instrucciones básicas por las veces resuelven la complejidad de sumar dos números, comprobar si un número es cero, mover datos de una parte de la memoria a otra, etc.

El conjunto de las instrucciones primitivas de una computadora forma un lenguaje con el cual podemos comunicarnos con ella. Dicho lenguaje se llama lenguaje máquina. Existen lenguajes que son más fáciles de usar que el lenguaje máquina, los cuales hacen uso de un compilador, a estos lenguajes se les conoce como lenguajes de alto nivel. El compilador se encarga de transformar las instrucciones en lenguaje de alto nivel a lenguaje máquina.

Un sistema de datos bien diseñado proporciona a los usuarios la información necesaria para tomar decisiones mediante la recolección eficiente de datos, su procesamiento y la comunicación de la información resultante. Un sistema de esta naturaleza puede incluir procedimientos manuales, empleo de formas comerciales, archivos de datos y, por supuesto, programas computacionales.

El procesamiento de datos administrativos tiene varias características especiales respecto a la entrada de datos, su procesamiento y la salida de dichos sistemas. La entrada de datos normalmente es voluminosa y consiste en registros de datos numéricos y no numéricos de longitudes variables. El procesamiento de la entrada de datos comerciales se caracteriza por la actualización de los archivos. La salida se caracteriza por la producción de reportes que agrupan resumen datos por categorías significativas que corresponden a varias funciones.

Cuando se tiene una gran cantidad de registros para procesar lo más conveniente es usar archivos de acceso directo. El acceso directo se ha creado exclusivamente para computadoras que utilizan dispositivos de almacenamiento de disco. Los archivos de acceso directo tienen frecuente uso en directorios, tablas de artículos y precios, listas de nombres, etc. De hecho son frecuentemente utilizados en aplicaciones donde el acceso rápido a los datos es esencial teniendo éstos accesados de manera simple y rápida.

Como origen de la presente tesis se planteó la posibilidad de crear una herramienta de acceso a archivos la cual cumple con algunas de las funciones propias de un manejador de bases de datos, desarrollada con algún lenguaje de tercera generación como es el COBOL.

Esta herramienta deberá proporcionar la flexibilidad de acceso a los datos que proporciona una base de datos aprovechando los recursos de la empresa. Por otro lado esta herramienta deberá cumplir las características propias de un sistema en línea.

Como una primera opción se determinó que podría desarrollarse con archivos de tipo secuencial o secuenciales indexados por múltiples llaves, sin embargo como se verá más adelante este tipo de archivos son poco eficientes con sistemas en línea ya que son de acceso serial.

Como segunda opción se pensó solucionar el problema con archivos de acceso directo, sin embargo la experiencia que se tenía en este tipo de archivos es que solo podían accederse por una sola llave principal. Por tal razón se decidió realizar un manejador de archivos de acceso directo por diferentes llaves, lo cual viene siendo un manejador de bases de datos elemental. Con esta herramienta se podrán crear archivos por llaves primarias y alternas relacionando los datos entre sí.

La finalidad de la presente tesis es mostrar las bases de este proyecto así como el desarrollo del manejador de archivos de acceso directo por múltiples llaves.

## 1 DESCRIPCIÓN DE ARCHIVOS TRADICIONALES

La mayoría de los sistemas operativos proveen un conjunto básico de organización de archivos que son muy populares entre los usuarios del sistema. Los tres tipos de organización de archivos más comunes son: el secuencial, el secuencial indexado y el directo.

### 1.1 Archivos Secuenciales

En un archivo secuencial, los registros son almacenados uno después de otro en el dispositivo de almacenamiento. Debido a que la asignación secuencial es conceptualmente simple, todavía es lo bastante flexible para hacer frente a muchos de los problemas asociados con la manipulación de grandes volúmenes de datos, un archivo secuencial ha sido la más popular de las estructuras de archivos básicas usadas en la industria del procesamiento de datos.

Todos los tipos de dispositivos de almacenamiento externo soportan un archivo de organización secuencial. Algunos dispositivos, por su naturaleza física, solamente pueden soportar archivos secuenciales, por ejemplo, la información es almacenada en una cinta magnética como una serie continua de registros a lo largo de la cinta. Para acceder un registro en particular se requiere acceder todos los registros previos en el archivo. Otros dispositivos que son estrictamente secuenciales por naturaleza son: lectoras de cinta de papel, lectoras de tarjetas, cintas de cassette e impresoras en línea.

Los discos y tambores magnéticos proveen acceso secuencial y directo a los registros. Los registros de un archivo secuencial son almacenados físicamente en lugares adyacentes de una pista de un disco o tambor. Si el archivo es más grande que la cantidad de espacio existente en una pista, entonces los registros son almacenados en pistas adyacentes. Este concepto de adyacencia física puede ser extendido a cilindros y dispositivos de almacenamiento completo donde más de un dispositivo es tomado como una unidad de control común.

Las operaciones que pueden ser realizadas en un archivo secuencial pueden diferir significativamente, dependiendo del dispositivo de almacenamiento usado. Por ejemplo, un archivo en cinta magnética puede ser un archivo de entrada a un archivo de salida pero no ambos a la vez. Un archivo secuencial en disco puede ser usado estrictamente para entrada estrictamente para salida o para ser actualizado. Actualizar significa que el registro leído más recientemente puede ser reescrito en el mismo archivo si se desea. Algunos sistemas operativos proveen facilidades para acceso de archivos que permiten que un archivo sea extendido para la escritura de registros después del último registro actual. También, algunas veces es posible mover hacia atrás o hacia adelante un cierto número de registros en el archivo sin hacer lectura o escritura.

Antes de explicar el tipo de procesamiento que es normalmente aplicado a los archivos secuenciales es importante examinar cómo la información en un archivo es transferida al programa de usuario y viceversa. Se sabe que a menudo es ventajoso agrupar un número de registros lógicos dentro de un simple registro físico o bloque. Los bloques completos son transferidos entre la memoria principal y el almacenamiento externo.

Cada vez que una instrucción de lectura es ejecutada, el próximo registro del archivo secuencial activo es movido dentro del área del programa y asignado a la estructura de datos. Sin embargo, cada vez que una operación de lectura o escritura es ejecutada para un dispositivo particular de almacenamiento, un bloque de registros lógicos es transferido. La diferencia entre las instrucciones de lectura y escritura de un programa con los comandos de lectura y escritura usados en un dispositivo particular se resuelve usando un área de almacenamiento temporal entre el almacenamiento externo y el área de datos de un programa. Esta área de almacenamiento temporal es una sección de memoria principal que es igual al tamaño máximo de un bloque de registros lógicos usados por un programa. Las rutinas del manejador de datos del sistema operativo usan dicha área para el bloqueo y desbloqueo de registros.

Para ilustrar cómo el bloqueo y desbloqueo de registros es realizado usando un área de almacenamiento temporal, consideremos el uso de un archivo secuencial como archivo de entrada. Cuando la primera instrucción de lectura es ejecutada, un bloque de registros es movido desde el almacenamiento externo al almacenamiento temporal. El primer registro en el bloque es después transferido al área de datos del programa. Por cada ejecución subsiguiente de

instrucciones de lectura, el próximo registro sucesivo en el almacenamiento temporal es transferido al área de datos. Solamente después de que cada registro en el almacenamiento externo ha sido movido al área de datos, en respuesta a instrucciones de lectura, la próxima instrucción de lectura provoca que otro bloque sea transferido al almacenamiento temporal desde el almacenamiento externo. Los nuevos registros en el almacenamiento temporal son movidos al área de datos, como se describió previamente, y este proceso es repetido completamente para cada bloque que se haya leído.

De modo similar, las instrucciones de escritura provocan la transferencia de los datos del programa al almacenamiento temporal. Cuando el almacenamiento temporal llega a estar completo, entonces el bloque es escrito en el dispositivo de almacenamiento externo inmediatamente después del bloque precedente de registros.

La técnica de almacenamiento temporal descrita es comúnmente llamada de almacenamiento temporal simple. La de almacenamiento temporal múltiple hace uso de una cola de áreas de almacenamiento temporal que son cuidadosamente controladas por el sistema operativo. La necesidad de más de un almacenamiento temporal surge debido al retardo (que es del orden de milisegundos) inherente en leer o escribir el próximo bloque de registros. Este retardo en la ejecución de un programa solamente ocurre a menudo cada  $n$  ejecuciones de las instrucciones de lectura o de escritura, cuando un factor de bloque de  $n$  y un solo almacenamiento temporal es usado. Sin embargo, si el programa se está ejecutando en un ambiente donde el tiempo de respuesta deseado es pequeño y donde el procesador y la actividad de entrada-salida son sobrepuestas, entonces es deseable eliminar este retardo usando múltiples almacenamientos temporales.

En algunos sistemas los bloques de registros lógicos que constituyen un archivo secuencial pueden ser de longitud fija o de longitud variable. Un bloque de longitud variable contiene un número variable de registros. Por lo tanto, no es conocido cuántos registros caben en un bloque y una longitud máxima es definida para el bloque. Esta longitud máxima es usada para establecer el tamaño del almacenamiento temporal requerido para contener el bloque, y tantos registros como es posible son agrupados dentro del bloque debido a las facilidades del manejador de datos.

la longitud máxima de un bloque depende del dispositivo de almacenamiento usado por el archivo, por esta razón a

la longitud depende del espacio máximo válido para el almacenamiento temporal en memoria principal, con

almacenamiento en disco, los bloques son generalmente limitados en tamaño a la capacidad de una pista, usando un

dispositivo de sector direccionable, un bloque corresponde al número máximo de sectores.

Ya que se ha explicado la estructura física de un archivo secuencial, como los registros son transferidos al

el área del programa de a él archivo se van a mencionar los tipos de procesamiento que para la mayoría de los

archivos secuenciales son convenientes. El procesamiento serial es el acceso de registros, uno después de otro, de

acuerdo al orden físico en que aparecen en el archivo. Es un asunto fácil procesar un archivo secuencial

serialmente. El procesamiento secuencial es el acceso de registros, uno después de otro, en orden ascendente o

descendente de acuerdo a la clave del registro, una vez que el archivo ha sido ordenado por su clave el

procesamiento secuencial es equivalente al procesamiento serial. La mayoría de los archivos secuenciales son

ordenados por su clave cuando el archivo es creado. La clave puede ser el campo que es más a menudo buscado durante

el procesamiento de el archivo.

En raras ocasiones, el procesamiento serial es totalmente requerido en un archivo, independientemente de la clave

bajo la cual el archivo está ordenado.

El procesamiento secuencial y serial son más efectivos cuando un alto porcentaje de los registros en el archivo

deben ser procesados. Ya que cada registro en el archivo debe ser examinado, un número de transacciones

relativamente grande podría ser procesada en lote. Si los registros serán agregados al archivo, es necesario crear

un nuevo archivo a menos que los registros sean agregados al final del archivo. En muchos sistemas no existen las

facilidades que permitan la extensión directa de un archivo secuencial. Los registros pueden ser borrados de un

archivo secuencial rotacionados como borrados durante la actualización del archivo. Sin embargo, este procedimiento

dirige a los archivos con registros ficticios a un almacenamiento ineficiente. El tiempo de procesamiento es

incrementado, usualmente, los registros borrados son físicamente eliminados creando un nuevo archivo. Cuando la

creación de un nuevo archivo es necesaria, puede ser hecha tan frecuentemente como sea requerida.

Los puntos importantes concernientes al proceso secuencial de archivos secuenciales son los siguientes:

El procesamiento secuencial es más lento que el procesamiento en lote. Las transacciones pueden ser hechas por un solo procesamiento en lote.

Un nuevo archivo puede ser creado si hay ediciones o si se requiere un número significativo de eliminaciones.

El tiempo de respuesta rápido no puede ser esperado para una transacción o un lote de transacciones.

El requerimiento de que los registros de un archivo secuencial sea ordenado por una llave particular no es fundamental si el archivo está siendo examinado para realizar la misma operación sobre todos los registros.

## 1.2 Archivos secuenciales indexados

Un aspecto importante que afecta la estructura del archivo es el tipo de medio físico en que reside el archivo. La capacidad de acceder directamente un registro basado en una llave puede solamente ser llevada a cabo si el dispositivo externo de almacenamiento usado soporta este tipo de acceso. Dispositivos tales como lectoras de tarjetas y unidades de cinta permiten el acceso de un registro particular solamente después de haber leído todos los otros registros que físicamente aparecen antes del registro deseado en el archivo. Por lo tanto el acceso directo de registros es imposible para estos tipos de dispositivos. Los dispositivos de almacenamiento externo que soportan el acceso directo y secuencial son las unidades de disco y también magnético.

Los conceptos de la estructura del archivo secuencial indexado son más especificados cuando se considera un disco magnético como el medio de almacenamiento. Debido a su baja relación precio/prestamiento y a su gran capacidad, los discos son generalmente escogidos cuando se usan archivos secuenciales indexados.

Se presentarán dos tipos de organización de archivo secuencial indexado. La primera organización de archivo secuencial indexado consiste de tres áreas separadas: el Área primaria, el Área indexada y el Área de sobreflujo. El Área primaria es una Área en la cual los registros de datos son escritos cuando el archivo es creado. El archivo es creado secuencialmente por la escritura de registros en el Área primaria en la secuencia dictada por el orden léxico de las llaves de los registros. El proceso de escritura se realiza en la segunda pista de un cilindro particular, por decir algo, en el cilindro n de un disco. Cuando este cilindro es llenado, la escritura continúa en la segunda pista

de el próximo cilindro (next) y continúe en esta fase hasta que la creación del archivo es completada. Si el archivo creado es accesado secuencialmente de acuerdo a la llave, los registros son procesados en el orden en que fueron recibidos.

La segunda área importante de un archivo secuencial indexado es el área de indexación, es creada automáticamente por las rutinas del manejador de datos del sistema operativo. Un número de niveles de indexación pueden ser involucrados en un archivo secuencial indexado. El nivel más bajo de indexación es el índice de pista, que está siempre escrito en la primera pista de los cilindros en que se encuentra el archivo secuencial indexado. El índice de pista contiene dos entradas por cada pista primaria de un cilindro: una entrada normal y una entrada de sobreflujo. La entrada normal está compuesta de las direcciones de la pista primaria para las cuales la entrada está asociada y de el más alto valor de las llaves de los registros clasificados en esa pista. Si no hay sobreflujo de registros, la entrada de sobreflujo es igual a la entrada normal. De la misma forma como un índice de pista describe el almacenamiento de registros en las pistas de un cilindro, el índice de cilindro indica como los registros son distribuidos sobre un número de cilindros.

En nivel final de indexación existe en esta estructura jerárquica indexada. Un índice maestro es usado para un archivo extremadamente grande en donde una búsqueda del índice de cilindro es también tiempo consumido. Este índice forma el nodo raíz del árbol de índices usado en un archivo secuencial indexado.

La localización de un registro con una llave dada involucra una búsqueda en el índice maestro para encontrar el índice de cilindro apropiado con que el registro está asociado. Posteriormente, se hace una búsqueda en el índice de cilindro para encontrar el índice de pista. Finalmente, una búsqueda de pista es requerida para localizar el registro deseado. Se debe hacer notar que un índice maestro no siempre es necesario y solamente debe ser requerido para archivos grandes. Cuando es usado debe existir en memoria principal durante todo el proceso de un archivo secuencial indexado.

Si se agregan registros en un archivo secuencial, un nuevo archivo secuencial debe ser creado. Podemos usar el mismo principio para el manejo de adiciones en un archivo secuencial indexado.

sin embargo, porque es posible acceder registros directamente en un archivo secuencial indexado, este tipo de archivo es usado generalmente en un ambiente más volátil y de respuesta rápida. Por ejemplo, un ambiente en que surgen muchas ediciones y eliminaciones es durante transacciones en línea o pequeños lotes de transacciones. Tales ediciones y eliminaciones deben ser inmediatamente reflejadas en el archivo.

Los problemas de agregar registros son resueltos por la creación de una área o áreas de sobreflujo, usualmente en el mismo dispositivo en el que reside el archivo. Dos tipos de áreas de sobreflujo son posibles: una área de sobreflujo de cilindro y una área de sobreflujo independiente. Una área de sobreflujo de cilindro es un número de pistas dedicadas en un cilindro que contienen un número de pistas de áreas primarias. Si, a través de la edición de un registro, un sobreflujo es creado en las pistas del área primaria del cilindro, entonces los registros de sobreflujo son almacenados en el área de sobreflujo del cilindro.

Cuando más registros son agregados al archivo secuencial indexado, se llena el área de sobreflujo. Cuando esto sucede, los futuros registros de sobreflujo son transferidos al área de sobreflujo independiente. El área de sobreflujo independiente reside en un cilindro o en cilindros independientes de cualquier área primaria del cilindro. Estos registros de sobreflujo son ligados de la misma manera en que están en el área de sobreflujo del cilindro. Se nota, sin embargo, que para discos con cabezas bobines, el uso de áreas de sobreflujo deben ser desechadas debido al aumento significativo de las quedas que son generadas cuando el brazo de acceso es movido entre las áreas primaria y de sobreflujo independiente.

Hasta ahora hemos explicado la adición de registros, vamos ahora a considerar la eliminación de registros. En esta organización de archivo secuencial indexado, los registros no son borrados físicamente de el archivo, pero son marcados como borrados haciendo "11111111" en el primer byte del registro. Si un nuevo registro es agregado más tarde y con la misma clave que el registro previamente borrado, entonces el espacio ocupado por el registro borrado es recuperado.

Los registros que son colocados en el área de sobreflujo nunca son regresados al área primaria para ser borrados.

Solamente por la reorganización del archivo puede un registro de sobreflujo ser colocado en el área primaria. La reorganización es llevada a cabo secuencialmente copiando los registros del archivo en un archivo temporal y después recreando el archivo mediante una copia secuencial de los registros de respaldo en el archivo original. Debido a que la recuperación de registros de sobreflujo puede ocurrir un sobrecalentamiento, la cantidad de desorganización de un archivo secuencial indexado debe ser monitoreada continuamente.

El segundo archivo secuencial indexado está organizado en bloques de datos y en bloques de índices. Ambos bloques son manejados como registros lógicos que son asignados y transferidos a y de memoria principal bajo la dirección de un monitor. El usuario no tiene control sobre el lugar físico de los bloques en el dispositivo de almacenamiento externo. Este sencillo sistema de control es un requerimiento necesario debido a que el monitor permite compartir los archivos del disco en un ambiente multiusuario. El usuario tiene control sobre el tamaño de los datos y sobre los bloques de índices.

Un bloque de datos está compuesto de registros lógicos con apuntadores a los registros de datos dentro del bloque de datos y un espacio reducido en el cual los registros de sobreflujo son colocados, es importante hacer notar que este espacio de sobreflujo es un factor del tamaño del bloque completo.

Un bloque de índices contiene parejas de llaves, de direcciones y un pequeño espacio para agregar tales parejas. Una pareja (clave dirección) está compuesta de la clave más baja de un bloque de datos particular y la dirección del dato en que esta clave reside. El usuario puede seleccionar un factor del área de sobreflujo para el bloque de índices y puede especificar el número de niveles de índices para el archivo cuando es creado.

Cuando más bloques de datos son creados, el bloque de índices llega a estar completo. Los sobreflujos en un bloque de índices son manejados en la misma forma que los bloques de datos. Un nuevo bloque es creado y la mitad de los registros índice en el bloque completo de índices son copiados en un nuevo bloque de índices. La razón para particionar el bloque de sobreflujo es eliminar el problema que continuamente se tiene al colocar registros de sobreflujo desde un bloque completo a un área de sobreflujo separata. Por supuesto que el proceso de partición requiere más memoria que el proceso de sobreflujo de un registro a la vez debido a que el espacio de partición debe ser reservado.

Los registros borrados son procesados por el receptor de basura. Es decir, los agujeros dejados por los registros borrados son reemplazados por los registros activos con la clave más grande en el bloque. El área de registros activos y las áreas de partición son siempre áreas contiguas en un bloque.

Ahora se va a examinar el tipo de procesamiento que es realizado cuando se usa un archivo secuencial indexado. Por el momento debe estar claro que la organización de un archivo secuencial indexado es mucho más compleja que la de un archivo secuencial. Debido a esta complejidad, la mayoría de los sistemas operativos proveen facilidades o métodos de acceso que manejan los cambios de la estructura del archivo que pueden resultar de la inserción y eliminación de registros.

La principal ventaja de un archivo secuencial indexado es que los registros pueden ser procesados secuencial o directamente. El procesamiento secuencial de un archivo secuencial indexado es lógicamente idéntico al procesamiento secuencial de un archivo secuencial. Los registros son procesados en una secuencia determinado de acuerdo a la clave. Los tipos de transacciones que pueden ser realizadas son lectura, edición, borrado y eliminación de registros. Estos son completados en el nivel de usuario con instrucciones de lectura, escritura y reescritura. La forma en que se efectúan estas transacciones es esencialmente igual para el procesamiento secuencial tanto de los archivos secuenciales como de los archivos secuenciales indexados. La manera en que los registros son procesados es sustancialmente diferente, debido a las diferencias en las estructuras de los archivos.

Para concluir, se mencionaran las propiedades importantes de los archivos secuenciales indexados.

- El archivo secuencial indexado provee un acceso razonablemente mas rapido a los registros usando el procesamiento directo o el procesamiento secuencial.
- Para archivos relativamente estaticos, el area de sobreflujo puede ser eliminada y el area de sobreflujo del cilindro puede ser eliminada, esto da como resultado un alto porcentaje de la utilizacion del disco.
- Para archivos altamente volatiles, el tiempo de acceso para un registro llega a ser excesivo cuando las areas de sobreflujo estan llenas.
- Las facilidades para el acceso secuencial indexado son generalmente dadas en la mayoria de los sistemas, esto releva al programador de una gran cantidad de trabajo detallado en el mantenimiento de las areas de indices y de sobreflujo. En el nivel de programador, el procesamiento secuencial de un archivo secuencial indexado aparece identico al procesamiento secuencial de un archivo secuencial.

### 1.3 Archivos directos

En un archivo directo, tambien llamado aleatorio, una transformacion o mapeo es hecho de la llave del registro a la direccion de la localidad de almacenamiento en que reside el archivo. Un mecanismo usado para generar esta transformacion es llamado algoritmo de dispersion. Los algoritmos de dispersion son aplicados para localizar los registros en una tabla de dispersion. Un algoritmo de dispersion consiste de dos componentes: una funcion de dispersion que define un mapeo del espacio llave al espacio direccion y una tecnica de resolusion de colisiones que resuelve conflictos que surgen cuando mas de un registro llave es mapeado a la misma direccion.

Los algoritmos de dispersión usados para archivos directos son muy similares a los usados para tablas. La principal diferencia usual se debe a las características físicas del almacenamiento externo, que son diferentes de las características del almacenamiento direccionado directamente usado para las tablas. En particular el tiempo de acceso para un registro en una tabla en memoria principal es del orden de microsegundos, mientras que el tiempo de acceso para un registro en memoria externa es del orden de milisegundos. En suma los registros en un archivo son almacenados en áreas de almacenamiento direccionables, en las cuales cada área de almacenamiento direccionable contiene  $b$  localidades de registro. El número de registros en un área de almacenamiento direccionable es llamado la capacidad del área de almacenamiento direccionable.

Básicamente se puede pensar en un área de almacenamiento direccionable como un sector en un dispositivo direccionable por sector, o como un bloque en un dispositivo direccionable por bloque. Para un registro en particular a ser aislado, el área de almacenamiento direccionable en la que el registro reside debe ser localizada, el contenido del área de almacenamiento direccionable es traído a un almacenamiento temporal en memoria, y después el registro deseado es extraído del almacenamiento temporal.

Se va a definir un espacio de dirección  $A$  de tamaño  $n$  tal que el conjunto  $A = \{i_1, i_2, \dots, i_{n/b}\}$ , donde  $b$  es una constante entera. Entonces los registros pueden ser acomodados por  $A$ , y el factor de carga para el archivo directo es  $n/(nb)$ , asumiendo que una llave de tamaño  $n$  es mapeado dentro del espacio  $A$ .

Un conjunto llave  $S = \{x_1, x_2, \dots, x_b\}$  es un subconjunto de un conjunto  $K$  de posibles llaves que es llamado el espacio llave. Si el tamaño de  $K$  es igual al número de localidades de registro en  $A$ , y la llave es consecutiva, entonces una transformación puede ser definida para asignar a cada área de almacenamiento direccionable de  $A$  exactamente  $b$  llaves desde  $S$ . Este tipo de transformación uno a uno es llamado direccionamiento directo. En la mayoría de las situaciones,  $S$  es un pequeño subconjunto de  $K$  y resulta muy bajo el uso del direccionamiento directo. Si  $S$  es mapeado dentro de  $A$  con todas las distintas posibilidades, los registros serán asignados a la misma área de

Almacenamiento direccionable e mejor que un Área de almacenamiento direccionable de sobreflujo se lleve a cabo cuando está sujeta una función de manejo de sobreflujo de área de almacenamiento direccionable debe ser usada para almacenar los registros de sobreflujo. Las técnicas de manejo de sobreflujo de área de almacenamiento direccionable son muy similares a las de resolución de colisiones en una tabla.

Las funciones de dispersión se dividen en dos clases generales: distribuido independiente y distribución dependiente.

El método de división, usando un divisor primo o un divisor que es relativamente primo con el tamaño del espacio direccionable, tuvo el mejor rendimiento en promedio. Esto no quiere decir que para ciertos conjuntos clave con ciertas funciones de carga y repartidas de área de almacenamiento direccionable, uno de los otros métodos existentes no pueda reemplazar al método de división.

Recientemente, han sido fuertemente interesantes las técnicas de dispersión que facilitan a un archivo crecer dinámicamente sin requerir una partición significativa de redistribución. Estas técnicas son particularmente aplicadas a la organización de archivos directos. Aunque estas involucran transformaciones de dirección más complicadas, resulta significativamente reducido el número de colisiones.

El segundo aspecto del algoritmo de dispersión es la teoría de resolución de colisiones. En un archivo directo, la unidad más pequeña direccionable es el Área de almacenamiento direccionable, que puede contener muchos registros que han sido sujetos a la misma dirección. Por lo tanto, en un archivo directo con una capacidad de área de almacenamiento direccionable dada, un cierto número de colisiones son esperadas. Cuando hay muchos registros colisionados que la capacidad del Área de almacenamiento direccionable entonces algún método debe ser encontrado para el manejo de esos registros de sobreflujo. El término técnica del manejo de sobreflujo es usado en lugar de técnica de resolución de colisiones, que es el término adoptado para los métodos de tablas de dispersión.

La misma clasificación general puede ser aplicada para los técnicas de manejo del sobreflujo. Cuando usamos un área de almacenamiento direccionable con una capacidad mayor que uno, estamos de hecho haciendo una forma restringida de prueba lineal de un direccionamiento abierto. Cuando un registro es agregado a un área de almacenamiento direccionable que no está llena, el nuevo registro es agregado a la próxima localidad abierta. Seguramente que la próxima localidad de registro abierta esté en el área de almacenamiento direccionable, ya está reservada para registros que son mapeados a las direcciones de ese área de almacenamiento direccionable.

El área de almacenamiento direccionable referenciada por el cálculo de la dirección de un registro es llamada como el área de almacenamiento direccionable primaria para ese registro. Si un registro no está presente en el área de almacenamiento direccionable primaria, está localizado en un área de almacenamiento direccionable de sobreflujo, o no está en el archivo.

Desde que el contenido completo de un área de almacenamiento direccionable es traído a memoria principal por un requerimiento, es extremadamente beneficioso que el registro deseado esté localizado en alguna parte del área de almacenamiento direccionable primaria. Si el registro no está en el área de almacenamiento direccionable primaria, un requerimiento debe ser hecho para traer un área de almacenamiento direccionable de sobreflujo, la cual es determinada por el método de manejo de sobreflujo.

Si el método de sobreflujo de prueba lineal de direccionamiento abierto es usado, entonces una búsqueda sucesiva es hecha de los registros en las áreas de almacenamiento direccionables sobrantes del archivo. La búsqueda es terminada satisfactoriamente cuando el registro es localizado. Es terminada insatisfactoriamente si un registro vacío es encontrado, o si la búsqueda retorna al área de almacenamiento direccionable originalmente probada.

Una prueba aleatoria de direccionamiento abierto a de doble dispersión no son necesariamente buenos métodos de sobreflujo en el caso de búsquedas directas. En ambos métodos las secuencias de áreas de almacenamiento direccionables de sobreflujo que son examinadas no exhiben la propiedad de adyacencia física. Es decir, dos áreas de almacenamiento direccionables que son adyacentes en la secuencia de sobreflujo no son necesariamente adyacentes físicamente. La adyacencia física puede ser importante, ya que los registros que no son adyacentes físicamente tienen una alta probabilidad de requerir una búsqueda en un dispositivo de almacenamiento de cinta o disco. El tiempo de la búsqueda extra puede ser prohibitivo.

Los registros de sobreflujo pueden ser encadenados desde el área primaria a un área de sobreflujo separada. Un registro de sobreflujo debe residir en un área de almacenamiento direccionable de sobreflujo que está en la misma área de búsqueda del área primaria para dicho registro de sobreflujo. Particularmente, una buena estrategia es reservar las últimas áreas de almacenamiento direccionables de un área de búsqueda estrictamente para los registros de sobreflujo de las áreas de almacenamiento direccionables primarias en esa área. Esta es la estrategia apropiada cuando se vive el área de sobreflujo de un cilindro en la organización secuencial inversada. Sin embargo, puede ser difícil adoptar tal estrategia de configuración, ya que los áreas de almacenamiento direccionables de sobreflujo podrían romper el esquema de direccionamiento lineal requerido para un direccionamiento directo. Por lo tanto, un área de sobreflujo independiente que está totalmente separada del área primaria puede ser requerida.

Una estrategia final de sobreflujo también involucra encadenamiento. Existe un método llamado encadenamiento con listas unidas. Con este método, los registros de sobreflujo son localizados usando apuntadores de un área de almacenamiento direccionable a otra. Por lo tanto, cuando una llave es dispersada en un área de almacenamiento direccionable, una búsqueda comienza a través de una cadena de áreas de almacenamiento direccionables hasta el registro requerido o hasta que una localidad de almacenamiento válida es encontrada. Las llaves pueden ser mapeadas a áreas de almacenamiento direccionables que no sean las primeras en una cadena. Es necesario que las listas estén unidas. En una cadena de áreas de almacenamiento direccionables, las llaves que son originalmente dispersadas a diferentes direcciones pueden ser encontradas.

Esto demuestra que el encadenamiento con listas separadas requiere la longitud promedio más pequeña de búsqueda sin embargo, este aparente ventaja es superada debido a dos factores. Primero, el área de sobreflujo separada no cuenta como parte del espacio total del archivo. Por lo tanto, si n registros son agregados al archivo, todos los n registros son localizados en el área primaria, usando direccionamiento abierto o encadenamiento con listas unidas. Si hay m sobreflujos entonces m+n registros son localizados en el área primaria cuando se usa encadenamiento con listas separadas. Por lo tanto, el factor efectivo de carga es menor para el encadenamiento con listas separadas.

El segundo factor contribuye al mejor rendimiento de cualquier método de encadenamiento sobre un método de dirección abierto. Para el método de encadenamiento, la información concerniente a la localización del próximo registro de sobreflujo es almacenada en el mismo registro. Así que, al buscar un registro de sobreflujo particular, no hay necesidad de examinar un número intermedio de registros que pueden no ser registros de sobreflujo. Se debe hacer notar que las ligas del almacenamiento de sobreflujo dependen el tamaño del registro. Esto puede ser una consideración importante para el diseño del archivo, especialmente si el archivo consiste de muchos pequeños registros.

Un punto final que debe tenerse en mente es que el acceso a un área de sobreflujo independiente probablemente resultará en un rendimiento de búsqueda. Por lo tanto, si los dispositivos externos de cabeza móvil están siendo usados, el encadenamiento a un área de sobreflujo independiente puede no ser un método eficiente. Un posible compromiso es ampliar el encadenamiento con listas unidas.

Se ha centrado la explicación de las estructuras de archivo para archivos directos sobre las técnicas de dispersión. Hay otros métodos para organizar un archivo directo que son menos populares pero no obstante pueden ser aplicados en algunas situaciones.

Si el número de registros en el archivo es relativamente pequeño y el tamaño del registro es relativamente grande entonces puede ser que valga la pena considerar un esquema de direccionamiento directo. Algunos métodos para llevar a cabo la transición directa de la dirección involucran el uso de referencias cruzadas o indexación. Una tabla de

Referencias cruzadas es simplemente una tabla de claves y direcciones en la que una dirección de almacenamiento externo es asignada a cada clave. La localización de un registro dada su clave es simplemente recuperar la dirección externa asociada con la clave y después usar un comando de entrada/salida que recupere directamente el registro deseado. En la mayoría de los lenguajes de programación las listas asociadas no son previstas y el programador debe manejar la tabla de referencias cruzadas. La tabla puede ser guardada como una lista desordenada y tiene a menudo asociada con ella una búsqueda binaria o alguna técnica usual de entrar una dirección. Alternativamente, la tabla puede ser representada como una lista ordenada por la clave y una búsqueda binaria puede ser empleada para encontrar más rápidamente una dirección. La edición y eliminación de registros presentan problemas debido a que la tabla debe ser mantenida en orden.

Los métodos de indexación incluyen árboles binarios, árboles B y sus, y otros tipos de estructuras que pueden ser escogidas para llevar acabo búsquedas directamente en archivos directos. Con los métodos de árbol estructurado la edición y eliminación de registros puede ser manejada más efectivamente.

En este capítulo se ha expuesto que si un registro deseado no está localizado en su área de almacenamiento direccionable primaria, entonces una serie de comandos de entrada/salida es usado para acceder a un área de almacenamiento direccionable de subrefugio al cual es examinado para buscar el registro requerido. La estrategia de búsqueda es válida para unidades de memoria externa que son direccionables por sector. Algunos dispositivos direccionables por registro son capaces de localizar una especie física, un registro particular en una pista dada basándose en la clave del registro. En otros dispositivos, gracias a su soporte físico, se elimina mucho de la inspección de las áreas de almacenamiento direccionables de subrefugio en memoria principal debido al hecho que se usan dispositivos direccionables por sector.

El procesamiento del archivo directo es dependiente de la forma en que la clave del registro es transformada a una dirección del dispositivo externo. Los archivos directos son primeramente procesados directamente. Es decir, una clave es mapeada a una dirección y dependiendo de la naturaleza del archivo de transacción, un registro es creado, es borrado, es salvado o es accesado en dicha dirección o posiblemente en algunas direcciones subsiguientes si una

colisión se lleva a cabo. Ello que, la dirección subsecuente es determinada por la técnica de manera de sobreflujo que es adaptada. Cuando un método de sobreflujo es arrojado usando enlazamiento con listas separadas, un apuntador a la lista ligada de los registros de sobreflujo es incluido en cada área de almacenamiento direccionable. El acceso aleatorio directo se ha creado exclusivamente para computadores que utilizan dispositivos de almacenamiento en disco. Los métodos de acceso directo tienen frecuente uso en directorios, tablas de artículos y precios, listas de nombres etc. De hecho son frecuentemente utilizados en aplicaciones en donde la longitud de los registros de datos es corta y fija y el acceso rápido a los datos es esencial siendo estos accesados siempre de manera simple y rápida. En estos casos la organización de los archivos directos es la única adecuada. Acceso simple significa el uso de una clave simple para acceder la información.

El método de acceso directo simple es con frecuencia el más rápido conocido para acceder registros físicos, sin embargo existen tres características que hacen de este método a menudo impráctico, tales características son:

- Su dependencia de registros de longitud fija
- Los argumentos de recuperación del dato están limitados solo a un atributo de la llave
- No existe la filosofía de acceso en serie, ya que para conocer el siguiente dato al actual se requiere conocer previamente la llave

Actualmente en muchas aplicaciones existen adaptaciones que se pueden utilizar para superar estas limitaciones. Una de ellas es el almacenamiento en bloques. Cuando se utiliza este tipo de almacenamiento se pueden tener registros de

longitud de los atributos serán almacenados en un bloque. Para poder efectuar este tipo de organización se requiere una estructura de datos que indique cuál es el siguiente registro lógico que sucede al actual. Este método de organización es más complejo, sin embargo permite la búsqueda de información en forma serial.

#### Acceso directo por atributos múltiples

Este método de acceso es conveniente cuando el requerimiento para acceder un registro no está limitado solo a un atributo de una clave. Bajo estas condiciones el método de acceso directo simple no soluciona el problema, ya que es necesario poder acceder con atributos diferentes un mismo registro.

Para poder acceder la información en estas condiciones se requiere tener una lista de direcciones por cada clave diferente que se quiera localizar. Cada aspecto de direcciones podría ser localizado con una función de transformación diferente para cada lista de apuntadores.

Este método ayuda a ahorrar espacio en disco ya que solo es necesario mantener un registro de datos completo el cual puede ser accedido por diferentes atributos.

Las listas de apuntadores contienen solamente la dirección en donde se encuentra el registro de datos actual. Con este método se pueden utilizar múltiples listas de apuntadores para acceder el registro de datos por claves diferentes.

Los registros de datos serán encontrados de acuerdo a alguna clave por lo que deberá existir una lista de apuntadores y una regla de transformación para cada uno de estos. El valor de la dirección que contenga el aspecto de direcciones más pequeño indicará la dirección en donde se encuentra el registro de datos.

El registro de datos puede ser localizado directamente por su primer llave e indirectamente por sus llaves alternas. Con este método no todos los atributos requieren tener espacios de direcciones diferentes, el espacio dependerá de la longitud en caracteres del atributo más un espacio para escribir la dirección del registro de datos.

Así también el espacio de datos podrá tener una organización diferente ya sea un pila, vertical o aleatoria.

Una inserción dentro de un archivo que utiliza listas de apuntadores múltiples requiere que todas las listas de apuntadores sean actualizadas, así también una modificación a una de estos atributos requiere que se actualicen todas las listas.

Todas las entradas con el mismo valor de llave tendrán la misma dirección en el espacio de apuntadores, esto incrementa el riesgo de colisiones para atributos los cuales no son únicos, por ejemplo, una fecha, nacionalidad, sexo etc.

Cuando se trabaja con archivos directos simples cuyos registros son almacenados por un solo atributo, esperamos o es deseable que estos sean únicos, por ejemplo, un número de cuenta, un número de asiento, un número de empleado, un registro federal de causantes etc., de esta forma solo corresponderá una dirección en el espacio de direcciones de datos.

Algunas llaves del registro de datos pueden no ser únicas, en estas condiciones la función de transformación asignará la misma dirección a atributos repetidos, esta situación puede resolverse mediante el mecanismo de almacenar los registros en bloques dentro de un mismo registro físico.

Las principales propiedades de este tipo de archivos son:

- El acceso directo a registros en un archivo directo es rápido, especialmente para archivos con un bajo factor de carga y pocos registros de sobreflujo
- Debido a que cierta sección del archivo permanece sin uso para prevenir un excesivo número de registros de sobreflujo, la utilización del espacio para un archivo directo es pobre comparada con otros tipos de organizaciones de archivo
- El rendimiento conseguido usando un archivo directo es muy dependiente del algoritmo de transformación llave a dirección adaptado. La transformación que es usada es una aplicación dependiente y es generalmente implementada y mantenida a través de los programas de usuario
- Los registros pueden ser accedidos seriamente pero no secuencialmente a menos que una lista ordenada de llaves separede esa mantenido

## 2 DISEÑO DE LAS ESTRUCTURAS DE DATOS

Las estructuras de datos que se utilizarán se exponen en este capítulo pero antes es conveniente recordar los conceptos básicos de las diferentes estructuras de datos existentes.

### 2.1 Descripción de las estructuras de datos tradicionales

Las estructuras de datos se pueden dividir en dos grupos: lineales y no lineales. Se dice que una estructura de datos es lineal cuando los datos se encuentran almacenados en localidades de memoria adyacentes y es no lineal cuando los datos se almacenan en localidades dispersas.

## 2.1.1 Estructuras de datos lineales

Los elementos enteros, reales, caracteres son llamados primitivos porque dentro del repertorio de instrucciones de una computadora existen instrucciones que manipulan estas estructuras primitivas.

Las estructuras de datos no primitivas pueden ser clasificadas como arreglos, registros, y listas. Una variable de tipo estructurado difiere de una de tipo simple en que las variables de un tipo estructurado tienen más de una componente. Cada componente de un tipo estructurado es una variable que puede tener una estructura simple o estructurada. En el nivel más bajo, las componentes de una variable estructurada tienen tipos simples, y a estos pueden ser asignados valores e usados en expresiones en la misma forma que las variables simples. La cuestión fundamental de una variable estructurada es la manera en la cual sus componentes son accesadas. Las variables del tipo arreglo y registro nos permiten usar la memoria del computador en forma más flexible; el tipo archivo permite que la información almacenada en medios externos a la memoria sea accesada.

Un arreglo es una colección de variables las cuales todas tienen el mismo tipo. Una línea de un texto puede ser representada como un arreglo de caracteres, un vector puede ser representado como un arreglo de números reales, y como una matriz consiste de columnas, cada una de las cuales es un vector, una matriz puede ser representada como un arreglo de vectores.

Un tipo arreglo es declarado en términos de un tipo índice y un tipo componente. Los elementos del arreglo son almacenados en palabras consecutivas de la memoria de la computadora. Esta es una forma eficiente de almacenar las componentes enteras y reales, porque en muchas computadoras estas requieren una palabra entera de la memoria o más.

Sin embargo, esto no es siempre una manera eficiente de almacenar variables de otros tipos, porque el espacio puede desperdiciarse. La cantidad de espacio desperdiciado puede reducirse etiquetando varias componentes de un arreglo dentro de cada palabra.

Un arreglo es un conjunto ordenado que consiste de un número fijo de elementos. Las operaciones de eliminación e inserción de elementos no pueden ser realizadas sobre arreglos.

Un registro, como un arreglo, es una variable estructurada por varios elementos. Los elementos de un registro pueden tener tipos diferentes y a ellos se accede por nombre y no por subíndice.

Tanto arreglos como registros son abstracciones de formas de almacenamiento de datos usados en el nivel de lenguaje de máquina.

Los nombres de los elementos deben ser únicos dentro del registro. Los nombres de los elementos se pueden usar para denotar una variable o un elemento de otro registro. No existen operadores que puedan usar registros como operandos, sin embargo, el valor de un registro puede ser asignado a otro registro por una proposición de asignación.

Una lista es un conjunto ordenado que consiste de un número variable de elementos y donde se pueden hacer inserciones y eliminaciones de sus elementos. Una lista que despliega el parentesco de adyacencia entre sus elementos se dice que es lineal. Cualquier otra lista se dice que es no lineal.

Las operaciones que se pueden hacer en una lista son las mismas que se hacen sobre un arreglo, pero hay una importante diferencia: que el tamaño de la lista puede ser cambiado continuamente. La inserción y eliminación de elementos en una lista es especificado por la posición. Es decir, se puede borrar el elemento  $i$ -ésimo de una lista o insertar un nuevo elemento antes o después del elemento  $i$ -ésimo. Cada elemento en una lista está compuesto de uno o más campos. Un campo puede ser considerado la pieza más pequeña de información que puede ser referenciada en un lenguaje de programación. Las siguientes operaciones se pueden realizar sobre listas:

- Combinar dos o más listas para formar otra lista.
- Dividir una lista en varias listas.

- Copiar una lista.

- Determinar el número de elementos en una lista.

- Clasificar los elementos de una lista en orden ascendente o descendente, dependiendo de ciertos valores de uno o más campos dentro de un elemento.

- Buscar un elemento dentro de una lista que contiene un campo con cierto valor.

Un archivo es una gran lista que está almacenada en memoria externa de una computadora. Los archivos permiten almacenar grandes cantidades de datos, evitando con esto volver a dar datos a un programa cada vez que se ejecuta. Los archivos pueden ser manipulados desde diferentes programas con diferentes propósitos.

La estructura de un archivo es semejante a la de un arreglo unidimensional. En un arreglo el índice de un elemento puede ser un entero negativo, cero o un entero positivo. En un archivo el valor del índice del primer elemento es siempre cero y el valor del último es  $n-1$  siendo  $n$  el número de registros o elementos de los que consta el archivo. El elemento o registro de un archivo puede ser una variable simple (entera, real, etc.) o una variable estructurada (registro). La dimensión de un arreglo permanece sin cambio a lo largo de la ejecución de un programa, mientras que un archivo solo puede crecer (agregar registros) a lo largo de la ejecución de un programa.

Los archivos son importantes por tres razones. Primera, un proceso solo se puede comunicar con su medio ambiente por medio de archivos. Segunda, un proceso es usualmente de vida corta: un programa se carga en la memoria principal y se ejecuta, y tan pronto como termina la memoria es usada por otro programa. Si el programa no modifica un archivo durante su ejecución, no habrá evidencia de que este corrió completamente. La tercera razón para la importancia de los archivos es que pueden almacenarse cantidades más grandes de datos en un archivo que en la memoria principal.

Una de las estructuras de datos lineales de tamaño variable más importante es la pila. Es la forma más general de una lista lineal: se pueden insertar o eliminar elementos que se encuentren en cualquier posición. Una pila es una subclase de lista que permite la inserción y la eliminación de un elemento solamente a través de un extremo. La operación de inserción es conocida como meter y la operación de eliminación es conocida como sacar. El mayor y el menor elemento accesible en la pila son conocidos como el tope y el fondo respectivamente.

Ya que las operaciones de inserción y eliminación de elementos son realizadas por uno de los extremos de la pila sus elementos sólo pueden ser sacados en orden inverso en el que ellos fueron metidos a la pila, este tipo de lista lineal es frecuentemente conocido como LIFO (último en entrar, primero en salir).

Las operaciones sobre una pila pueden ser simuladas mediante el uso de un vector consistente de un número de elementos suficientes de acuerdo a las posibles inserciones que se quieran hacer a la pila.

Un apuntador guarda el estado del tope de la pila, inicialmente, cuando la pila está vacía el apuntador tiene un valor de cero y cuando la pila tiene un solo elemento el apuntador tiene un valor de uno, y así sucesivamente. Cada vez que un nuevo elemento es introducido en la pila, el apuntador es incrementado en uno, antes de que el elemento sea colocado en la pila. El apuntador es decrementado en uno cada vez que una eliminación es hecha. Las pilas tienen aplicación sobre procesos de recursividad y de notación infija.

Otro importante tipo de lista es la cola que permite que las eliminaciones sean realizadas por uno de sus extremos y las inserciones por el otro. La información de esta lista es procesada de la misma forma en que fue recibida, es decir, primero en entrar, primero en salir (FIFO). Existen dos apuntadores en una cola, uno en el extremo por el que entran los datos y otro en el extremo por el que salen, cuando la cola está vacía o tiene un solo elemento ambos apuntadores coinciden.

### 3.1.2 Estructuras de datos no lineales

Una gráfica ó **grafista** (como GNA.8), es una relación de A sobre un conjunto A. Los elementos de A son llamados **nodos** y los elementos de B son llamados **arcos**.

Si en un arco es importante considerar el nodo inicial y el nodo final entonces se está hablando de un arco dirigido. Una gráfica cuyos arcos son todos dirigidos es llamada **gráfica dirigida**. El grado externo de un nodo es el número de arcos que salen de él. El grado interno de un nodo es el número de arcos que llegan a dicho nodo. Si en una gráfica dirigida el nodo final de un arco es el nodo inicial de otro arco y así sucesivamente entonces se dice que se trata de una **trayectoria**. Si el nodo inicial y final de la trayectoria es el mismo se trata de un ciclo. Una gráfica que contiene al menos un ciclo es llamada **gráfica cíclica** de otra forma es llamada **acíclica** cuando los arcos de la secuencia son distintos. La trayectoria es simple si los arcos son distintos y contienen a todos los nodos de A. La trayectoria es **hamiltoniana**. La longitud de una trayectoria es el número de arcos que la componen.

Si en un arco no es importante considerar cuál es el nodo inicial ni cuál es el nodo final se habla de un arco no dirigido. Un arco cuyo nodo inicial y final son los mismos se conoce como un lazo. La dirección de un lazo no tiene ningún significado y puede ser considerada como un arco dirigido o no dirigido. Una gráfica es no dirigida cuando todos los arcos son no dirigidos.

Una gráfica es **mixta** cuando contiene arcos dirigidos y no dirigidos. Una gráfica que tiene algunos nodos unidos por más de dos arcos, inclusive, con el mismo sentido, son llamados **arcos paralelos**. Una gráfica que contiene arcos paralelos se llama **multigráfica**. En caso de contener un arco entre cualquier par de nodos se llama **gráfica simple**. Existen grafistas a cuyos arcos se les asigne valores, estos valores son llamados **peso del arco** y dan origen a una **gráfica llamada pesada**.

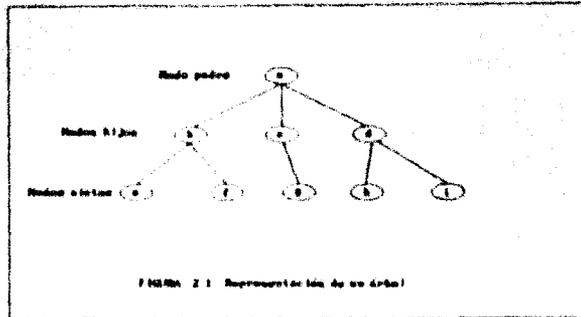
Una gráfica dirigida, con  $n$  nodos, puede ser completamente especificada con una matriz de orden  $n$  llamada matriz de adyacencia. Para definir la matriz debe considerarse que cualquier elemento  $x_{ij}$  de la matriz es igual a 1 si existe un arco entre los nodos  $i$  y  $j$ , es igual a cero si no hay arco. En una gráfica dirigida y pesada el elemento  $x_{ij}$  de la matriz de adyacencia es igual al peso del arco si el arco existe entre los nodos  $i$  y  $j$  y es igual a cero si el arco no existe. Una gráfica no dirigida, pesada o no, puede representarse por una matriz triangular, ya que los arcos del nodo  $i$  al nodo  $j$  y del nodo  $j$  al nodo  $i$  son los mismos.

Un árbol es una gráfica  $G=(A, E)$  en la que

- El número de nodos es igual al número de arcos más uno.
- Todos los nodos son de grado interno uno, excepto un nodo llamado la raíz, de grado cero.
- No hay ciclos.
- Cualquier trayectoria es simple.
- Entre cualquier par de nodos sólo hay una trayectoria.
- Cualquier arco es un arco de desconexión.

En la terminología que se emplea para el estudio de los árboles se encuentran los términos siguientes:

- Se define como grado externo de un nodo al número de sus subárboles.
- Una hoja o nodo terminal es una hoja de grado externo cero.
- Un nodo ramal es un nodo de grado externo mayor que cero.
- El nivel de un nodo es el nivel de su antecesor directo más uno.
- Los nodos de un árbol reciben nombres tales como el nodo  $a$  es padre de los nodos  $b$ ,  $c$  y  $d$  ya que el nodo  $a$  es su antecesor directo. Los nodos  $b$ ,  $c$  y  $d$  son hermanas ya que se encuentran al mismo nivel (figura 2.1).



Un árbol es ordenado cuando los subárboles tienen un orden cuando esto no ocurre el árbol es orientado. En este último caso, si la dirección de los arcos se ignora, el árbol es libre.

Un árbol puede ser completamente especificado por una matriz de adyacencia de forma similar a una gráfica dirigida. Para especificar el nodo raíz, es posible utilizar los elementos de la diagonal principal que siempre estarán disponibles. Cuando un árbol es libre, la matriz de adyacencia es triangular, y se especifica en forma similar a una gráfica no dirigida.

Un árbol particular que tiene gran importancia en el área de las ciencias de la computación es el árbol binario. Esto se debe fundamentalmente a la sistemización que puede lograrse para su representación. Un árbol binario es un árbol en el que cualquier nodo tiene cero, uno o dos subárboles. Cuando tiene exactamente cero o dos subárboles es llamado árbol estrictamente binario. De otra forma, es un árbol de Knuth.

Un árbol estrictamente binario es balanceado cuando el número de nodos terminales  $n$  es igual a  $2^m$ , y la longitud de cualquier trayectoria de la raíz a cualquier nodo terminal es igual a  $m$ , donde  $m$  es cualquier número entero no negativo, o si  $2^m < n < 2^{m+1}$  y la longitud de las trayectorias es  $m$  o  $m+1$ .

## 2.2 Diseño de las estructuras de datos

Las estructuras de datos más importantes que se utilizan son cinco: la primera es para el archivo directo principal, para el área de sobreflujo y para el área de sobreflujo especial, que en este caso en particular es de una llave principal, dos llaves secundarias y un solo campo de información. La segunda es para los parámetros de control del archivo directo principal, la tercera es para el archivo de apuntadores por cada subllave, la cuarta es para los parámetros de control del archivo directo de apuntadores de cada subllave y, la quinta es para la localización de los archivos. las estructuras, para este caso particular de una llave principal y dos llaves secundarias se muestran a continuación:

Registro del archivo directo principal, de su área de sobreflujo y del archivo directo de sobreflujo especial

- llave uno - llave principal de 4 caracteres
- llave dos - llave secundaria de 2 caracteres
- llave tres - llave secundaria de 1 carácter
- otro dato - campo de información de 3 carácter

Parámetros de control del archivo directo principal

- llave mínima - llave principal mínima de 4 caracteres
- llave máxima - llave principal máxima de 4 caracteres
- dirección mínima - dirección mínima del archivo directo principal
- dirección máxima - dirección máxima del archivo directo principal
- frecuencia - número de llaves existentes entre la llave principal mínima y la máxima
- llave promedio - promedio de las llaves existentes entre la llave principal mínima y la máxima
- dirección promedio - dirección mínima más dirección máxima entre dos

#### Registro del archivo de apuntadores por cada subllave

- dirección anterior - dirección del archivo directo de apuntadores que precede a la dirección actual en el encadenamiento de direcciones
- dirección siguiente - dirección del archivo directo de apuntadores que sigue de la dirección actual en el encadenamiento de direcciones
- subllave - valor de la subllave en cuestión
- dirección principal - dirección del archivo directo principal en el que se encuentra la subllave

#### Parámetros de control del archivo directo de apuntadores por cada subllave

- dirección inicial - dirección donde comienza el encadenamiento de direcciones
- dirección final - dirección donde termina el encadenamiento de direcciones

#### Tabla de localización de archivos directos

Esta tabla tiene como objetivo definir un espacio de direcciones global, los espacios de direcciones que correspondan al espacio principal así como los espacios de los apuntadores de las llaves alternas.

Tiene la siguiente estructura

- número de archivo - indica el archivo al que se debe referir el usuario para acceder datos de este espacio de direcciones.

- dirección inicial - este campo contiene un número el cual indica en donde inicia el espacio de direcciones del archivo en referencia.
- dirección final - este campo contiene un número el cual indica en donde termina el espacio de direcciones del archivo en referencia. Cuando se trate del archivo principal el espacio entre dirección inicial y dirección final incluye el espacio de direcciones para el área de sobreflujo el cual se determina calculando un diez por ciento del espacio total.

### 2.3 Ventajas de las estructuras de datos diseñadas

Con respecto a la estructura de datos del archivo directo principal, que es la misma para las dos áreas de sobreflujo, solo se trata de ejemplificar la utilización del manejador de archivos de acceso directo por múltiples llaves ya que como puede notarse sólo se tiene un campo de información de 1 carácter.

La ventaja de los parámetros de control del archivo directo principal es la de dividir el intervalo de llaves en subintervalos ya que dichos elementos no son continuos, es decir que si se tiene una llave y no necesariamente existe una llave  $y+1$  y otra llave  $y+1$ , si no que por lo general una llave  $y$  está entre una llave  $a$  y una llave  $b$  donde  $a$  y  $b$  no son iguales en la mayoría de los casos. Por otro lado, una dirección  $d$  siempre se encuentra entre una dirección  $d-1$  y otra dirección  $d+1$ , excepto sólo para los casos de la dirección mínima y máxima del intervalo de direcciones donde se tendrá una  $d-1$  y una  $d+1$  respectivamente, es decir dicho intervalo es continuo entre la dirección mínima y la dirección máxima (figura 2.7).

Se eligió dividir el intervalo en  $10^{(n-k)}$  subintervalos, donde  $n$  es el número de caracteres de la llave principal, ya que esto representa una milésima parte del intervalo total de llaves lo cual replica que si se tiene una llave principal de 6 caracteres habrá 1000 subintervalos y cada subintervalo tendrá sus propios parámetros de control, con esto se asegura una dispersión más eficiente en el archivo directo principal como se mostrará más adelante en este trabajo.

Cada subintervalo  $i$  tiene una llave mínima  $llamini$ , una llave promedio  $llaproi$ , una llave máxima  $llamasi$ , y una frecuencia de llaves  $frella_i$ , las cuales están asociadas con una dirección mínima  $dirmini$ , una dirección promedio  $dirproi$ , una dirección máxima  $dirmasi$ , y una frecuencia de direcciones  $fredir_i$ , respectivamente figura (2.2).

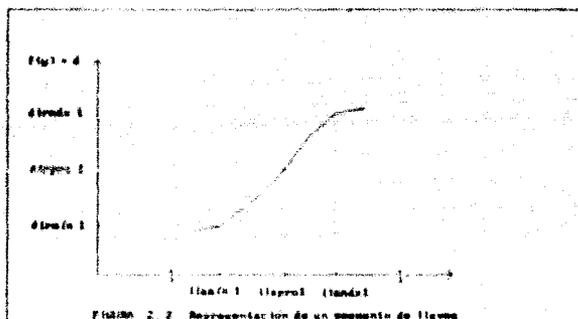


Figura 2.2. Representación de un segmento de llaves.

Es importante hacer notar que  $frella_i$  es igual a  $fredir_i$ , con el fin de asegurar una dirección por cada llave que exista en el intervalo  $i$ .

El registro del archivo directo de apuntes por cada subllave facilita el acceso por una de las llaves secundarias al archivo directo principal ya que los registros del archivo directo de apuntes se encuentran encadenados mediante los campos de dirección anterior y dirección siguiente para cada subllave particular, y en cada registro encadenado se encuentra la dirección del archivo directo principal en la cual aparece la subllave por lo

que solo se necesitan dos accesos por registro cuando se desea acceder al archivo directo principal por alguna subclave, un acceso al archivo directo de apuntadores donde se obtiene la dirección del archivo directo principal en que se encuentra dicha subclave y el acceso al archivo directo principal.

La ventaja de los parámetros de control del archivo directo de apuntadores es que indican el inicio y el final del encadenamiento de direcciones para una subclave en particular, lo cual facilita que si una subclave es de 2 caracteres habrá 1000 parámetros de control para el archivo directo que contenga los encadenamientos de direcciones para dicha subclave.

Es conveniente tener una tabla de localización de archivos ya que de esta forma se pueden conocer los límites de cada archivo directo sin tener que hacer algún otro cálculo.

### 3 DISEÑO DE LA FUNCIÓN DE DISPERSIÓN Y DE LA RESOLUCIÓN DE COLISIONES

Un manejador de archivos de acceso directo está formado principalmente por un método de dispersión y un método de resolución de colisiones los cuales se explicarán a continuación.

#### 3.1 Descripción de los métodos de dispersión tradicionales

Las funciones de dispersión se pueden dividir en tres grandes clases llamadas: funciones de distribución independiente, funciones de distribución dependiente y funciones de dispersión dinámica. Una función de dispersión de distribución independiente no usa la distribución de llaves para calcular la posición de un registro. Una función

de dispersión de distribución dependiente es obtenida después de haber examinado las llaves correspondientes de los registros conexos. Una función de dispersión directa se utiliza cuando el tamaño de la tabla de dispersión debe ser estimado durante el avance.

### 3.1.1 Métodos de dispersión de distribución independiente

Algunas de las propiedades deseadas de una función de dispersión incluyen la rapidez y la generación de direcciones uniformemente. Algunas llaves tienen caracteres alfanuméricos y es conveniente convertir tales caracteres a una forma para que pueden ser más fácilmente manipulados por la función de dispersión, este proceso es conocido como precondicionamiento. Dicho precondicionamiento es más productivo si se usa el código numérico de representación interna, como por ejemplo, ASCII o EBCDIC.

#### El método de la división

Una de las primeras funciones de dispersión y quizás la más ampliamente aceptada es el método de la división que se define como

$$H(x) = x \bmod m + 1$$

donde  $m$  es un divisor entero. El término  $x \bmod m$  tiene un valor que es igual al residuo de dividir  $x$  por  $m$ . En general, es muy poco común que un número de llaves produzcan el mismo residuo cuando  $m$  es un número primo muy grande.

#### El método del centro del cuadrado

Otro método que ha sido ampliamente usado en muchas aplicaciones es el método del centro del cuadrado. En este método una llave es multiplicada por sí misma y la dirección es obtenida seleccionando un número apropiado de bits o dígitos del centro del cuadrado. El número de bits o dígitos escogidos pueden ajustarse a una palabra de memoria de computadora.

#### El método editivo

En el método editivo una llave es seccionada en un número de partes cada una de las cuales tiene la misma longitud requerida para la dirección con la posible excepción de la última parte. Dichas partes son después sumadas, ignorando el acarreo final, para formar la dirección. Si las llaves están en forma binaria, la operación de or exclusivo puede ser substituida por la adición. A este método se le conoce como el método editivo directo. Existe una variación de este método conocida como el método editivo inverso en el cual se invierte el orden de los componentes de una llave de parte por antes de hacer la suma.

#### El método de longitud dependiente

Otra técnica de dispersión que ha sido comúnmente usada es llamado el método de longitud dependiente. En este método la longitud de la llave es usada junto con una parte de la llave para producir la dirección inmediatamente o una llave intermedia que será usada por otro método para producir, finalmente, una dirección.

### El método multiplicativo

Para una llave entera no negativa  $x$  y una constante  $c$  tal que  $0 < c < 1$ , se tiene la siguiente función de dispersión

$$H(x) = \text{trunc}(cx \bmod 1) \times 1$$

Donde  $\text{trunc}$  es la parte fraccional de  $x$ . Esta función de dispersión multiplicativa debe dar buenos resultados si la constante  $c$  es adecuadamente escogida. Una selección que es difícil de hacer.

Aunque alguno de estos métodos dan, frecuentemente, una distribución uniforme de las llaves sobre las direcciones, es necesario experimentar con funciones de dispersión aplicadas a un conjunto de llaves específicas. Se necesita una medida del rendimiento para comparar las diferentes funciones de dispersión y la medida más ampliamente aceptada es la longitud promedio de búsqueda. Para un conjunto de registros en un archivo directo, es el número promedio de accesos al dispositivo de almacenamiento requerido para recuperar un dato. Usualmente, la mejor función de dispersión para usar con un conjunto particular de llaves es la que minimiza la longitud promedio de búsqueda.

### 3.1.2 Métodos de dispersión de distribución dependiente

Una o más exámenes en un conjunto de llaves correspondientes a los registros conocidos deben ser realizados antes de que estas funciones puedan ser definidas. Tal que las inserciones y eliminaciones en el archivo pueden cambiar el conjunto de llaves drásticamente. La redefinición periódica de la función de dispersión y reorganización del archivo directo puede ser requerida.

El método de análisis digital

Una función de dispersión conocida como análisis digital forma las direcciones mediante la selección e inversión de los dígitos o bits de la llave original. Inicialmente un análisis en un conjunto de llaves es realizado para determinar que posiciones de la llave deben ser usadas para formar las direcciones. Las posiciones de los dígitos que tienen la distribución más uniforme son seleccionadas y posteriormente se invierte el orden de los dígitos para obtener la dirección deseada.

El método de intervalo acertado (lineal)

El espacio llave consiste de enteros en el intervalo  $(a, d)$ . Este intervalo es dividido en  $j$  subintervalos iguales de longitud  $L$ , donde  $L = (d-a)/j$ . El intervalo de localización para una llave  $x$  es expresado por la fórmula:

$$i = \lfloor (x-a)/L \rfloor$$

Los  $j$  intervalos pueden ser descritos como:

$I_1 = (a, a+L)$  para  $1 \leq i < j$

$I_j = (a+(j-1)L, a+jL)$  para  $2 \leq i < j$

la ecuación:

$$F_1(x) = (b_1 + (x - a_1) / (b_1 - a_1))^{1/n}$$

de la aproximación lineal de la función de distribución de frecuencia acumulativa para una llave  $x$  en el intervalo  $I_1$ . Dónde  $a_1$  y  $b_1$  son la frecuencia y la frecuencia acumulativa respectivamente del intervalo  $I_1$ ,  $A$  es el número de llaves. La función de dispersión requerida para una llave  $x$  sobre un intervalo  $I_1$  es:

$$H_1(x) = \text{round}(\text{int}(\text{int}(\text{int}(x), 10^4), 10^4), 10^4)$$

para un espacio de dirección de tamaño  $n$ .

#### El método de distribución de frecuencia múltiple

En este método un intervalo acertado lineal estimado de la distribución de frecuencia del espacio llave es usado para mapear dicho espacio en lugar del espacio dirección. Esto tiende a propagar fuera de los grupos de llaves y condensa ligeramente los intervalos poblados. El efecto total es que la distribución de llaves en el espacio llave tiende a ser más uniforme. El intervalo acertado lineal estimado de la distribución de las llaves transformadas es encontrado y puede ser usado en conjunción con la primer función del intervalo acertado lineal para formar una función de dispersión. Alternativamente, un número de iteraciones puede ser realizado hasta que la función de dispersión obtenida es juzgada como buena. El criterio usado para determinar el número de iteraciones es detener las iteraciones cuando la longitud promedio de búsquedas ha disminuido por un porcentaje insignificante (0.2) de una iteración a otra. Una llave del espacio original de llaves es usado para generar una dirección la cual es transformada en cada espacio llave, un intervalo acertado lineal estimado es usado para cada transformación.

### 3.1.3 Métodos de dispersión direccional

Una de las principales desventajas de los métodos de dispersión convencionales proviene de la organización externa de los archivos en la que el tamaño de la tabla de dispersión debe ser estimado en el avance. Dos problemas pueden surgir: si el tamaño de la tabla es pequeño la cantidad de los accesos llega a ser inaceptablemente lenta cuando la tabla se llena o cuando hay, sobreflujo; si el tamaño de la tabla es grande la utilización del área de sobreflujo resulta inaceptablemente baja. Todas las claves deben ser redistribuidas para el tamaño apropiado de la nueva tabla de dispersión y proveer un algoritmo para decidir cuándo esta redistribución debe llevarse a cabo. En este algoritmo el número de veces que cada clave es accesada es primero estimado. Considerando la longitud promedio de búsqueda antes y después de una redistribución proyectada, el decremento esperado en rate tiempo de búsqueda, resultante de una redistribución, es determinado. La tabla es completamente redistribuida si este decremento en el tiempo de búsqueda es mayor que el costo de la redistribución.

### El método de dispersión lineal

En la dispersión lineal la tabla es gradualmente expandida mediante la división de las áreas de almacenamiento direccional en orden hasta que la tabla ha duplicado su tamaño. Las áreas de almacenamiento direccional de sobreflujo pueden ser requeridas, pero si la función de dispersión seleccionada para la redistribución es bien escogida, la longitud promedio de búsqueda puede ser reducida significativamente. Una vez que la tabla ha duplicado su tamaño, el mismo método de expansión gradual es aplicado a la tabla agrandada, y así sucesivamente.

El tamaño de la tabla original es denotado por  $N_0$ . Después de  $d$  duplicaciones el tamaño de la tabla es  $N_d$ , que es el tamaño actual de la tabla y que se denota por  $N_p$ .

La dispersión lineal requiere el uso de una serie de funciones de dispersión  $H_0, H_1, H_2, \dots$ . Originalmente, la función de dispersión  $H_0$  es usada para producir un número entre 0 y  $H_0-1$ . Cuando el tamaño de la tabla es duplicado,  $H_1$  es usada para dar un número entre 0 y  $2H_0-1$ . En general  $H_n$  es usada para dar un número entre 0 y  $2^n H_0-1$ . El subíndice  $n$  apropiado con  $n$  indica el número de veces que ha sido duplicado el tamaño de la tabla original.

#### El método de dispersión extendible

Este método emplea una organización interna para la tabla índice, para representar la tabla índice se usa una estructura extendible en lugar de un árbol binario. La tabla índice contiene  $2^d$  posiciones, donde  $d$  es el número de bits más a la izquierda comúnmente usados para direccionar la tabla índice. Los  $d$  bits más a la izquierda de una clave, cuando es interpretada como un número, dan la posición en la tabla índice del apuntador al área de almacenamiento direccionable que contiene la clave. Originalmente la tabla contiene solamente una posición, la cual tiene un apuntador a la única área de almacenamiento direccionable en uso. Cuando esta área de almacenamiento direccionable se llena, la tabla índice duplica su tamaño, una nueva área de almacenamiento direccionable es creada y la claves son ordenadas apropiadamente. Las claves del área de almacenamiento direccionable de sobreflujo son redistribuidas entre una nueva área de almacenamiento direccionable. Uno de los nuevos apuntadores en la tabla índice debe de apuntar a la nueva área de almacenamiento direccionable y el otro al área de almacenamiento direccionable que no tiene sobreflujo. Como las claves adicionales son añadidas, la tabla índice duplica su tamaño siempre que una distribución basada en los bits de las claves es requerida para prevenir un área de almacenamiento direccionable de sobreflujo. Si que, si resulta que las claves no tienen una distribución uniforme una función de dispersión debe ser aplicada y las posiciones resultantes deben ser usadas para determinar una posición en la tabla índice y las respuestas subsiguientemente en un área de almacenamiento direccionable. Una serie desventajas para este esquema es que la tabla índice crece demasiado rápidamente para guardarla en memoria principal. Cuando parte o toda la tabla índice es almacenada en memoria secundaria, entonces accesos extra son requeridos para consultar esta tabla.

### 3.2 Diseño del algoritmo de dispersión

Se parte del hecho de que se tiene un conjunto de llaves principales  $\{y_1, y_2, \dots, y_n\}$  y  $E = \{f_1, f_2, \dots, f_m\}$ , y  $E \subseteq \mathbb{N}$  y se tiene un conjunto de direcciones definidas por  $\{d_1, d_2, \dots, d_m\}$ , donde  $\mathbb{N}$  es el conjunto de los números naturales, se sabe que el número de elementos de  $B$  por lo menos debe ser igual al número de elementos de  $Y$ , también se sabe que  $\{f_1, f_2, \dots, f_m\}$  que  $\{f_1, f_2, \dots, f_m\} \subseteq \mathbb{N}^{\text{longitud de la clave principal}}$ , donde longitud es el número de caracteres de la clave principal. El objetivo de la función de dispersión  $f$  es asociar a cada elemento del conjunto de llaves  $Y$  con un único elemento del conjunto de direcciones  $B$ , es decir, la función de dispersión  $f$  debe ser biunívoca como se muestra en la figura 3.1.

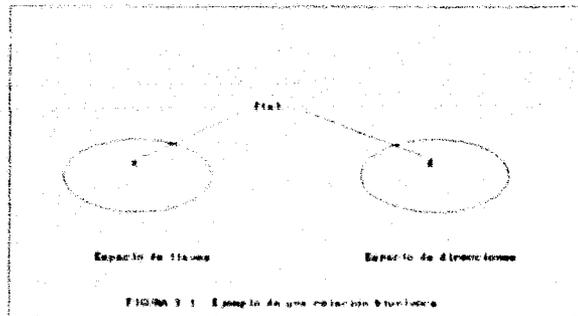


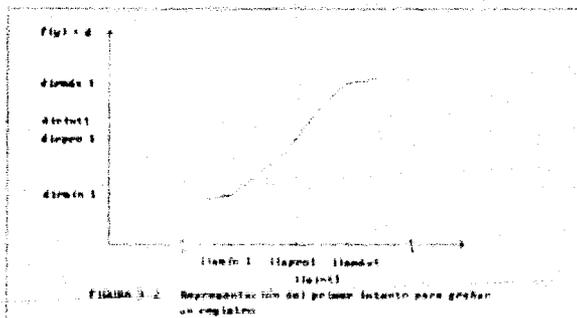
FIGURA 3.1 El mapa de una relación biunívoca

Sin embargo, en ocasiones varios elementos del conjunto de llaves  $Y$  están asociados con el mismo elemento del conjunto de direcciones  $B$ , en este caso se dice que se trata de una función no biunívoca, cuando esto sucede se utiliza un método de resolución de colisiones para que los elementos del conjunto de llaves colisionados se puedan asociar con algún elemento del conjunto de direcciones  $B$ , dicho método de resolución de colisiones se explicará posteriormente.

El primer algoritmo de dispersión que se diseñó fue el de suma-división que es una combinación del método binario con el método de la división. Los cuadros fueron explicados en el punto 3.1.1 de este trabajo.

Este método de suma-división consiste en sectionar la llave principal en un determinado número de partes donde cada parte tiene la misma longitud requerida para la dirección. dichas partes son sumadas, se ignora el acarreo final, el resultado de la suma se divide entre la frecuencia del intervalo al que pertenece la llave principal y finalmente el residuo de dicha división se suma a la dirección mínima del intervalo. Como a la dirección mínima se le suma el residuo de la división siempre se obtienen direcciones que se encuentran entre la dirección mínima y la dirección máxima ya que dicho residuo no puede ser mayor que la frecuencia y como se sabe la dirección máxima es igual a la dirección mínima más la frecuencia.

Posteriormente se pensó en diseñar una función de dispersión basada en siguiente gráfica y tomando en cuenta los parámetros de control del conjunto de llaves  $X$  y del conjunto de direcciones  $Z$  para cada intervalo (figura 3.2).



El segundo algoritmo de dispersión diseñado es una interpolación de Lagrange de primer orden. Bajo su uso se como interpolación lineal la cual consiste en que para un intervalo  $I$  de llaves  $\{llave_1, llave_2\}$  asociado con un intervalo  $J$  de direcciones  $\{direc_1, direc_2\}$ , a una llave intermedia  $llave_i$ , se le asocia una dirección intermedia  $direc_i$  mediante la siguiente fórmula:

$$direc_i = direc_1 + \frac{direc_2 - direc_1}{llave_2 - llave_1} (llave_i - llave_1)$$

En tercer lugar se diseña una función de dispersión basada en una interpolación de Lagrange de segundo orden aprovechando que para cada intervalo de claves  $i$  también se conoce su clave promedio  $llapro_i$ , la cual está asociada con la dirección promedio  $dirpro_i$ , la fórmula para este caso es la siguiente:

$$dirint_i = dirafn_i * ciafn_i + dirpro_i * cipro_i + diramx_i * ciamax_i$$

donde:

$$ciafn_i = ((llint_i - llapro_i) * (llamx_i - llamx_i)) / ((llamx_i - llapro_i) * (llamfn_i - llamx_i))$$

$$cipro_i = ((llamx_i - llamfn_i) * (llamx_i - llamx_i)) / ((llapro_i - llamfn_i) * (llapro_i - llamx_i))$$

$$ciamax_i = ((llamx_i - llamfn_i) * (llamx_i - llapro_i)) / ((llamx_i - llamfn_i) * (llamx_i - llapro_i))$$

### 3.3 Descripción de los métodos de resolución de colisiones tradicionales

Una función de dispersión puede mapear algunas claves a la misma dirección, cuando esta situación aparece los registros colisionados deben ser clasificados y accedidos mediante un método de resolución de colisiones. Dichos métodos se dividen en dos clases generales: direccionamiento abierto y encadenamiento. En general, el objetivo de un método de resolución de colisiones es producir un lugar para los registros colisionados en la tabla. Esto requiere la investigación de una serie de localidades en la tabla hasta que una localidad vacía es encontrada para acomodar el registro colisionado. Se requiere un mecanismo para generar la serie de localidades en la tabla ha ser examinadas. Los principales criterios para este mecanismo es la rapidez, seguridad y reproductividad.

### 3.3.1 Métodos de direccionamiento abierto

Si un registro con una llave  $x$  es mapeado a una localidad con dirección  $d$  y esta localidad está ocupada, entonces otras localidades de la tabla son examinadas hasta encontrar una vacía para el nuevo registro. La secuencia en la que las localidades de la tabla son examinadas pueden ser formuladas por diferentes caminos.

#### El método de prueba lineal

Uno de los métodos más simples para resolver colisiones es usar la siguiente secuencia de posiciones para una tabla de  $n$  entradas:  $d, d+1, \dots, d-1, n, 1, 2, \dots, d-1$ . Una localidad de registro es siempre encontrada si al menos hay una disponible. De otra forma, la búsqueda se detiene insatisfactoriamente después de examinar  $n$  localidades. Cuando se quiere recuperar un registro en particular, la misma secuencia de localidades es examinada hasta que el registro es encontrado o hasta que una localidad de registro vacía es encontrada. En este último caso el registro deseado no está en la tabla.

#### El método de prueba aleatoria

Este método genera una secuencia aleatoria de localidades más apropiada que en el caso de la prueba lineal. La secuencia aleatoria generada en esta fase debe contener localidades entre uno y  $n$  exactamente. Una tabla es llenada cuando la primer posición duplicada es generada.

### 3.3.2 Métodos de encadenamiento

Hay tres principales dificultades con el método de direccionamiento abierto. Primero, las listas de registros colisionados por diferentes valores de dispersión se llegan a entremezclar, este fenómeno requiere más pruebas. Segundo, no se puede manejar una tabla en situaciones de sobreflujó de una manera satisfactoria, al detectar un

sobreflujo la tabla completa debe ser reorganizada, el problema del sobreflujo no puede ser ignorado ya que el requerimiento de espacio puede variar drásticamente. Tercero, el borrado físico de registros es difícil. Para resolver estos problemas se usan métodos de localidades ligadas.

El método de encadenamiento separado

Es el más popular de los métodos de manejo de registros de sobreflujo. En este método los registros de sobreflujo son encadenados a un área especial de sobreflujo que es distinta del área primaria. Esta área contiene esa parte de la tabla en la cual los registros son inicialmente dispersados. Una lista ligada separada se mantiene por cada conjunto de registros ligados. Por lo tanto, un campo apuntador es requerido por cada registro en las áreas primarias y de sobreflujo. Un uso más eficiente de este método involucra el uso de una tabla intermedia o de una tabla de dispersión. Con este método todos los registros residen en el área de sobreflujo mientras que el área primaria contiene solamente apuntadores. Para una tabla con registros largos requiere un área de sobreflujo densamente equipada, es decir, mientras las entradas de la tabla de dispersión sean apuntadores los registros pueden ser largos sin desperdiciar mucho almacenamiento.

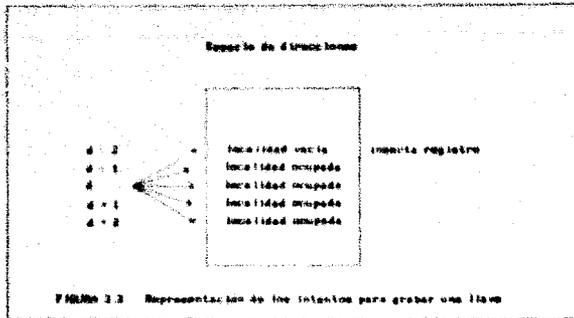
El número promedio de comparaciones, asumiendo una función de dispersión distribuida uniformemente, para acceder una entrada particular es ligeramente mayor que uno. Esto demuestra que el tiempo de búsqueda es independiente del número de entradas.

#### 3.4 Diseño del algoritmo de resolución de colisiones

El algoritmo de resolución de colisiones que se utiliza es una combinación del método de direccionamiento abierto con el método de encadenamiento separado.

Si a una llave principal  $k$  la función de dispersión  $f$  le asocia una dirección  $d$  cuyo registro ya está ocupado, para resolver la colisión se examinan las siguientes direcciones en el orden en que se muestran:  $d+1$ ,  $d-1$ ,  $d+2$ ,  $d-2$ .

ver figura 3.5



Si no se encontró una dirección con un registro desocupado la llave principal y es redispersada a un área de sobreflujo que pertenece al ambiente directo principal exclusivamente mediante una interpolación lineal la cual le asocia una dirección  $d$ .

$$d = \lfloor (i \cdot \text{infer} + \text{fasups} - \lfloor i \cdot \text{infer} \rfloor - \text{faifnf}) / (\text{fasups} - \text{faifnf}) \rfloor$$

donde:

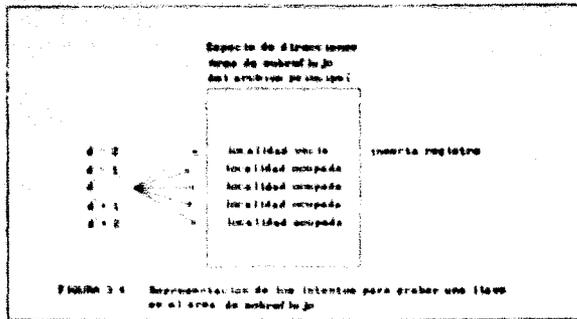
$\text{fasups}$  es el límite superior del área de sobreflujo

$\text{faifnf}$  es el límite inferior del área de sobreflujo

$\text{fasups}$  es el límite superior del intervalo de llaves

$\text{faifnf}$  es el límite inferior del intervalo de llaves

Si el registro que ocupa la dirección  $d$  ya está ocupado se prueban las direcciones siguientes en el orden en que se muestran:  $d+1$ ,  $d-1$ ,  $d+2$ ,  $d-2$ , ver figura 3.4.



Si nuevamente no se localizó una dirección con un registro desocupado la llave principal y es otra vez dispersada mediante una interpolación lineal pero ahora a una área especial de sobreflujo, la cual da servicio a más de un archivo directo principal, para obtener una dirección  $d'$ :

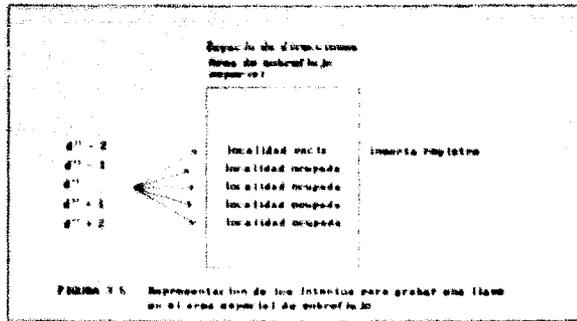
$$d' = \frac{(l_{\text{inf}} - l_{\text{sup}}) \cdot (l_{\text{sup}} - l_{\text{inf}}) + (l_{\text{sup}} - l_{\text{inf}}) \cdot (l_{\text{inf}} - l_{\text{sup}})}{l_{\text{sup}} - l_{\text{inf}}}$$

donde:

$l_{\text{sup}}$  es el límite superior del área de sobreflujo especial

$l_{\text{inf}}$  es el límite inferior del área de sobreflujo especial

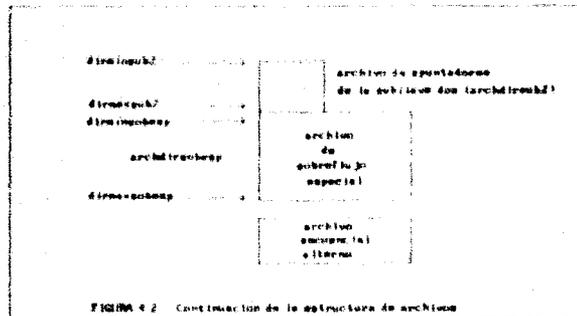
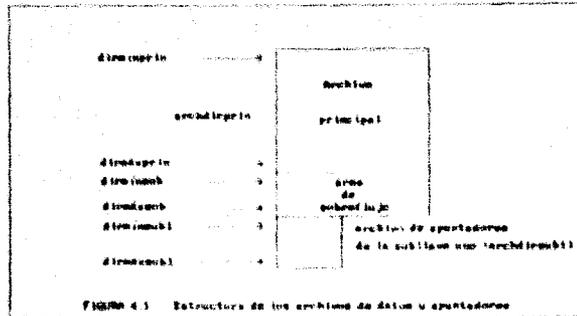
Si el registro con dirección  $d'$  ya está ocupado se prueban las direcciones siguientes en el orden en que se muestran:  $d'+1$ ,  $d'-1$ ,  $d'+2$ ,  $d'-2$ , ver figura 3.5.



En el peor de los casos si no se ha encontrado una dirección desocupada hasta este nivel el registro con llave principal y se manda a un archivo secuencial alternativo, esta es una posibilidad muy poco probable ya que para llegar a esta decisión se tienen que haber examinado 15 registros: 5 registros del archivo directo principal, 5 registros del área de sobreflujo del archivo directo principal y 5 registros del área de sobreflujo especial.

#### 4 SIMULACION DEL MANEJADOR DE ARCHIVOS

La representación esquemática de la localización de los archivos directos generados se muestra a continuación:



## Notenciatura

archseqent	archivo secuencial de entrada
archseqalt	archivo secuencial alterno
archdirprin	archivo directo principal
archdirsub1	archivo directo de apuntadores para la llave secundaria uno
archdirsub2	archivo directo de apuntadores para la llave secundaria dos
archdirsubesp	archivo directo de sobreflujo especial
totregent	total de registros en el archivo secuencial de entrada
numcarlia	número de caracteres de la llave principal
dirminprin	dirección mínima del archivo directo principal
dirmaxprin	dirección máxima del archivo directo principal
dirminsub	dirección mínima del área de sobreflujo del archivo directo principal
dirmaxsub	dirección máxima del área de sobreflujo del archivo directo principal
dirminsub1	dirección mínima del archivo directo de apuntadores para la llave secundaria uno
dirmaxsub1	dirección máxima del archivo directo de apuntadores para la llave secundaria uno
dirminsub2	dirección mínima del archivo directo de apuntadores para la llave secundaria dos
dirmaxsub2	dirección máxima del archivo directo de apuntadores para la llave secundaria dos
dirminsubesp	dirección mínima del archivo directo de sobreflujo especial
dirmaxsubesp	dirección máxima del archivo directo de sobreflujo especial
liemin	llave mínima del conjunto de llaves principales
liemax	llave máxima del conjunto de llaves principales
totint	total de intervalos del espacio de llaves

### 1.3. Descripción del manejador de archivos

Este manejador de archivos se realizó teniendo en cuenta que los datos de entrada se encuentran en un archivo secuencial por ejemplo en una cinta, pudiendo o no estar ordenados y que tienen que ser dispersados en un archivo directo de acuerdo a su llave principal, para un acceso más rápido. Todos los archivos directos que se explicaron son direccionables por registro lo cual implica el uso de una tabla donde se tiene la longitud del registro para cada archivo directo.

En este caso, el manejador de archivos de acceso directo consta de cuatro partes:

1) Programa generador de datos - en forma aleatoria genera los registros del archivo de entrada cuya estructura es de una llave principal, dos llaves secundarias y un campo de información de un carácter solo para ejemplificar que se puede tener almacenada más información.

2) Programa de dispersión de archivos - tiene el objetivo de dispersar todos los registros de entrada por su llave principal en el archivo directo principal de acuerdo a una de las tres funciones de dispersión que se explicaron en el capítulo 3.2, también se encarga de la resolución de colisiones, explicada en el capítulo 3.4 y por último, genera el archivo directo de apuntadores por cada subllave de las direcciones de los establecimientos.

3) Programa de acceso de archivo - accesa todos los registros del archivo directo principal en el orden en que fueron dispersados en base a la llave principal, también accesa dicho archivo por la llave secundaria uno, en orden ascendente y por la llave secundaria dos, en el mismo orden.

4) Programa de acceso por registro - accesa un registro del archivo directo principal por su llave principal o accesa un conjunto de registros de dicho archivo por una de las dos llaves secundarias.

Descripción del algoritmo de dispersión

Paso uno: obtener  $\text{totreg} = 10^{\text{numcarite} + 3}$  y dividir el intervalo de llaves principales en  $\text{totreg}$  intervalos

iguales, por ejemplo, si la llave principal es de 4 caracteres habrá 10 intervalos que son:

0-999, 1000-1999, 2000-2999, 3000-3999, 4000-4999, 5000-5999, 6000-6999, 7000-7999, 8000-8999, 9000-9999

Paso dos: obtener  $\text{dira}^{\text{exp}}_{\text{prin}}$ ,  $\text{dira}^{\text{ins}}_{\text{sob}}$ ,  $\text{dira}^{\text{ssob}}$ ,  $\text{dira}^{\text{insub1}}$ ,  $\text{dira}^{\text{ssub1}}$ ,  $\text{dira}^{\text{insub2}}$ ,  $\text{dira}^{\text{ssub2}}$ ,  $\text{dira}^{\text{insobesp}}$  y

$\text{dira}^{\text{ssobesp}}$  mediante

$\text{dira}^{\text{exp}}_{\text{prin}} = \text{dira}^{\text{exp}}_{\text{prin}} + \text{totregent} - 1$

$\text{dira}^{\text{ins}}_{\text{sob}} = \text{dira}^{\text{exp}}_{\text{prin}} + 1$

$\text{dira}^{\text{ssob}} = \text{dira}^{\text{ins}}_{\text{sob}} + \text{totregent}/10 - 1$

$\text{dira}^{\text{insub1}} = \text{dira}^{\text{ssob}} + 1$

$\text{dira}^{\text{ssub1}} = \text{dira}^{\text{insub1}} + \text{totregent} - 1$

$\text{dira}^{\text{insub2}} = \text{dira}^{\text{ssub1}} + 1$

$\text{dira}^{\text{ssub2}} = \text{dira}^{\text{insub2}} + \text{totregent} - 1$

$\text{dira}^{\text{insobesp}} = \text{dira}^{\text{ssub2}} + 1$

$\text{dira}^{\text{ssobesp}} = \text{dira}^{\text{insobesp}} + \text{totregent} - 1$

Es decir el tamaño del área de sobreflujo del archivo directo principal es igual al 10 por ciento del tamaño de dicho archivo.

Paso tres: leer en forma secuencial los totales del archivo y para cada intervalo de llaves principales obtener la llave mínima ( $llave_{i1}$ ), la llave máxima ( $llave_{i2}$ ), la frecuencia de llaves ( $frelle_i$ ) y la llave promedio ( $llapre_i$ ), es decir:

$$frelle_i = \sum_{k=1}^{totint} llave_k \cdot frelle_{ik}$$

Paso cuatro: por cada intervalo de llaves principales se asigna a la llave mínima y máxima su dirección mínima y máxima respectivamente mediante la suma de las frecuencias acumulativas, es decir:

$$\begin{aligned} diref_{i1} &= diref_{i0} \\ diref_{i2} &= diref_{i1} + frelle_i \\ diref_{i3} &= diref_{i2} + f \\ diref_{i4} &= diref_{i3} + frelle_i \end{aligned}$$

para  $i = 1, 2, \dots, totint$

De tal forma que  $diref_{i,totint} = diref_{i,0}$

Paso cinco: obtener la dirección ( $dirint_i$ ) para una llave principal ( $llave_i$ ) que se encuentre en el intervalo  $i$  mediante una de las tres funciones de dispersión diseñadas: suma de los dos, interpolación lineal o interpolación de Lagrange de segundo orden. La función de dispersión seleccionada se utilizará también para el acceso de registros.

Paso seis: si el registro que se encuentra en la dirección ( $dirint_i$ ) ya está ocupado, entonces revisar los registros que se encuentran en las siguientes direcciones: ( $dirint_i + 1$ ,  $dirint_i - 1$ ,  $dirint_i + 2$ ,  $dirint_i - 2$ ).

Paso siete: si no se encontró un registro desocupado, entonces a la llave principal (llant) se le asignará una dirección (dirsob) del área de sobreflujos del archivo directo principal mediante una interpolación lineal:

$$\text{dirsob} = \text{dirafnsob} + (\text{dirmaxsob} - \text{dirafnsob}) * (\text{llant} - \text{llafn}) / (\text{llams} - \text{llafn})$$

Paso ocho: si el registro que se encuentra en la dirección dirsob ya está ocupado, entonces revisar los registros que se encuentran en las siguientes direcciones: dirsob+1, dirsob-1, dirsob+2, dirsob-2.

Paso nueve: si no se encontró un registro desocupado, entonces a la llave principal (llant) se le asignará una dirección (dirsobesp) del archivo directo de sobreflujos especial mediante una interpolación lineal:

$$\text{dirsobesp} = \text{dirafnsobesp} + (\text{dirmaxsobesp} - \text{dirafnsobesp}) * (\text{llant} - \text{llafn}) / (\text{llams} - \text{llafn})$$

Paso diez: si el registro que se encuentra en la dirección dirsobesp ya está ocupado, entonces revisar los registros que se encuentran en las siguientes direcciones: dirsobesp+1, dirsobesp-1, dirsobesp+2, dirsobesp-2.

Paso once: si no se ha podido encontrar una dirección con un registro desocupado, entonces grabar el registro con llave p. principal (llant) en el archivo secuencial externo archseral.

Paso doce: grabar las direcciones correspondientes en el archivo directo de apuntadores para la llave secundaria uno.

Paso trece: actualizar el campo de dirección siguiente del registro anterior de la cadena en el archivo directo de apuntadores para la llave secundaria uno. También se actualiza el campo de dirección final del registro de control para la llave secundaria uno.

Paso catorce: grabar las direcciones correspondientes en el archivo directo de apuntadores para la llave secundaria dos.

Paso quince: actualizar el campo de dirección siguiente del registro anterior de la cadena en el archivo directo de apuntadores para la llave secundaria dos. También se actualiza el campo de dirección final del registro de control para la llave secundaria dos.

Paso dieciséis: repetir los pasos del cinco al quince hasta que se terminen de dispersar los setecientos registros del archent.

#### Descripción del algoritmo de acceso

Paso uno: obtener la dirección  $addr_{i,j}$  para una llave principal ( $key_{i,j}$ ) que se encuentre en el intervalo  $i$  mediante una de las tres funciones de dispersión diseñadas: suma-división, interpolación lineal o interpolación de Lagrange de segundo orden. La función de acceso seleccionada debe ser la misma que se utilizó para la dispersión de registros.

Paso dos: si el registro que se encuentra en la dirección  $dirint_1$  no es el que se busca, entonces revisar los registros que se encuentran en las siguientes direcciones:  $dirint_1+1$ ,  $dirint_1-1$ ,  $dirint_1+2$ ,  $dirint_1-2$

Paso tres: si no se encontró el registro deseado, entonces a la llave principal ( $llaint_1$ ) se le asignará una dirección ( $diraob$ ) del área de subflujo del archivo directo principal mediante una interpolación lineal:

$$diraob = dirafnab + (dirmaxob - dirafnab) * (llaint_1 - llain) / (llamx - llain)$$

Paso cuatro: si el registro que se encuentra en la dirección  $diraob$  no es el que se busca, entonces revisar los registros que se encuentran en las siguientes direcciones:  $diraob+1$ ,  $diraob-1$ ,  $diraob+2$ ,  $diraob-2$

Paso cinco: si no se encontró el registro deseado, entonces a la llave principal ( $llaint_1$ ) se le asignará una dirección ( $diraobesp$ ) del archivo directo de aflujo especial mediante una interpolación lineal:

$$diraobesp = dirafnabesp + (dirmaxobesp - dirafnabesp) * (llaint_1 - llain) / (llamx - llain)$$

Paso seis: si el registro que se encuentra en la dirección  $diraobesp$  no es el que se busca, entonces revisar los registros que se encuentran en las siguientes direcciones:  $diraobesp+1$ ,  $diraobesp-1$ ,  $diraobesp+2$ ,  $diraobesp-2$

Paso siete: si no se ha podido encontrar la dirección con el registro deseado entonces buscar el registro con llave principal  $llaint_1$  en el archivo secuencial alterno  $archsecalt$

Paso ocho: repetir los pasos del uno al siete hasta que se terminen de localizar los noventa y dos registros del archivo.

Paso nueve: hacer el acceso para la llave secundaria uno siguiendo el encadenamiento que se encuentra en el archivo directo de apuntadores generado durante la dispersión. Este acceso por encadenamiento utiliza dos accesos: un primer acceso al archivo directo de apuntadores de la llave secundaria uno donde se obtiene la dirección del archivo directo principal en la que se encuentra el registro con dicha llave secundaria y la dirección del siguiente registro en la cadena. El segundo acceso se hace al archivo directo principal.

Paso diez: repetir el paso nueve hasta que se terminen de recorrer las cadenas generadas para la llave secundaria uno.

Paso once: hacer el acceso para la llave secundaria dos siguiendo el encadenamiento que se encuentra en el archivo directo de apuntadores generado durante la dispersión. Este acceso por encadenamiento utiliza dos accesos: un primer acceso al archivo directo de apuntadores de la llave secundaria dos donde se obtiene la dirección del archivo directo principal en la que se encuentra el registro con dicha llave secundaria y la dirección del siguiente registro en la cadena. El segundo acceso se hace al archivo directo principal.

Paso doce: repetir el paso once hasta que se terminen de recorrer las cadenas generadas para la llave secundaria dos.

#### 4.2 DEMOSTRACION DE RESULTADOS

Los resultados generados se muestran a partir de las páginas siguientes en un total de 21 tablas, incluyendo los mensajes de error y las estadísticas obtenidas tanto para la dispersión de registros como para el acceso de los mismos. (Los resultados se obtuvieron a partir de un archivo de 20 registros generados en forma aleatoria, un registro se encuentra disponible cuando el campo de la llave principal tiene f1111).

Se explica el método de interpolación de Lagrange porque es con el que se obtuvieron mejores resultados.

El orden en que se muestran los resultados es de acuerdo a como se fueron generando.

Tabla 1 - Archivo secuencial de datos de entrada.

Tabla 2 - Parámetros de control del archivo secuencial de datos de entrada.

Tabla 3 - Muestreo de dispersión de los registros por su llave principal.

Tabla 4. 4 - rastreo del encadenamiento de los registros por su llave secundaria uno.

Tabla 4. 5 - rastreo del encadenamiento de los registros por su llave secundaria dos.

Tabla 4. 6 - parámetros de control del archivo directo de apuntadores con las direcciones de los encadenamientos para la llave secundaria uno

Tabla 4. 7 - parámetros de control del archivo directo de apuntadores con las direcciones de los encadenamientos para la llave secundaria dos.

Tabla 4. 8 - archivo directo principal

Tabla 4. 9 - archivo directo de sobreflujo especial

Tabla 4. 10 - archivo directo de apuntadores con las direcciones de los encadenamientos para la llave secundaria uno

Tabla 4. 11 - archivo directo de apuntadores con las direcciones de los encadenamientos para la llave secundaria dos.

Tabla 4. 12 - rastreo del acceso completo del archivo directo principal por su llave principal

Tabla 4. 13 - rastreo del acceso completo del archivo directo principal por su llave secundaria uno

Tabla 4. 14 - rastreo del acceso completo del archivo directo principal por su llave secundaria dos

Tablas 4. 15 a 4. 17 - rastreo del acceso interactivo con el usuario del archivo directo principal para cuatro llaves principales proporcionadas

Tablas 4. 18 a 4. 19 - rastreo del acceso interactivo con el usuario del archivo directo principal para cuatro llaves secundarias del tipo uno proporcionadas

Tablas 4. 20 a 4. 21 - rastreo del acceso interactivo con el usuario del archivo directo principal para cuatro llaves secundarias del tipo dos proporcionadas

Finalmente, se muestran los mensajes enviados por el manejador de archivos durante la corrida interactiva.

Tabla 4.1

EJEMPLO PARTICULAR CON UNA LLAVE PRINCIPAL Y

DOS LLAVES SECUNDARIAS

ARCHIVO DE DATOS DE ENTRADA

NUMERO REGISTRO	LLAVE PRINCIPAL	SUBLlave DOS	SUBLlave TRES	OTRO DATO
1	198	8	5	H
2	7624	33	8	H
3	2795	8	0	H
4	6221	24	4	H
5	8218	82	4	H
6	2620	35	0	H
7	870	67	8	H
8	4650	92	0	H
9	3414	20	1	H
10	5851	20	7	H
11	3670	84	2	H
12	7783	74	3	H
13	4837	13	3	H
14	469	97	5	H
15	313	30	3	H
16	6682	24	1	H
17	1378	42	7	H
18	2135	28	6	H
19	7239	76	4	H
20	1034	51	1	H

.....  
CLAVES PRINCIPALES REPETIDAS EN EL AREA DE ENTRADA ARGENT  
.....

.....  
CLAVE                      DIRECCION                      REPETICION  
.....  
.....

.....  
NUMERO DE REGISTROS REPETIDOS    0  
.....

PARAMETROS DE CONTROL DEL ARCHIVO DIRECTO PRINCIPAL

INTER-	LLAVE	LLAVE	LLAVE	FRECUEN-	DIREC-	DIREC-	DIRECCION
VALD	MINIMA	MAXIMA	PROMEDIO	CIA	MINIMA	MAXIMA	PROMEDIO
1	194	870	4 625E+02	4	2003	2006	2 002E+03
2	3034	1378	1 206E+03	2	2005	2006	2 005E+03
3	2135	2795	2 517E+03	3	2007	2009	2 008E+03
4	3414	3670	3 542E+03	2	2010	2011	2 010E+03
5	6650	4837	4 743E+03	2	2012	2013	2 012E+03
6	5851	5853	5 851E+03	1	2014	2014	2 014E+03
7	6221	6682	6 451E+03	2	2015	2016	2 015E+03
8	7239	7783	7 549E+03	3	2017	2019	2 018E+03
9	8218	8218	8 218E+03	1	2020	2020	2 020E+03
10	11111	0	0 000E+00	0	0	0	0 000E+00

Tabla 4.1

RASTRO DE LA DISPERSION DE LA LLAVE PRINCIPAL

RE	LLAVE	ACCESO	EN	DIRECCION		CAMPO	TIPO
UID	PRIN	MU	TER	ALIU	DISPER	LLAVE	SUBPR
FRO	CIPAL	NE	VALD	LADA	SADA	PRINCL	LLAVO
1	198	1	L	1	2001	2001	11111
1	198	2	E	1	2001	2001	198
2	7624	3	L	8	2018	2018	11111
2	7624	4	E	8	2018	2018	7624
3	2795	5	L	3	2009	2009	11111
3	2795	6	E	3	2009	2009	2795
4	6221	7	L	7	2015	2015	11111
4	6221	8	E	7	2015	2015	6221
5	8218	9	L	9	2020	2020	11111
5	8218	10	E	9	2020	2020	8218
6	2620	11	L	3	2008	2008	11111
6	2620	12	E	3	2008	2008	2620
7	870	13	L	1	2004	2004	11111
7	870	14	E	1	2004	2004	870
8	4650	15	L	5	2012	2012	11111
8	4650	16	E	5	2012	2012	4650
9	3414	17	L	4	2010	2010	11111
9	3414	18	E	4	2010	2010	3414
10	5851	19	L	6	2014	2014	11111
10	5851	20	E	6	2014	2014	5851
11	3670	21	L	4	2011	2011	11111

TABLA 4.1

MASTRO DE LA DISPERSION DE LA LLAVE PRINCIPAL

RE- GIS	LLAVE PRIN	ACCESO NU TI	IN- TER	DIRECCION CALCU	CAMPO DISPER	TIPO LLAVE	SUBRE FLUJO
IND	CON.	ME PO	VALO	LEGA	ADA	PRIMEJ	FLUJO
11	3670	22 E	4	2011	2011	3670	
12	7783	23 L	8	2019	2019	11111	
12	7783	24 E	8	2019	2019	7783	
13	4837	25 L	5	2013	2013	11111	
13	4837	26 E	5	2013	2013	4837	
14	669	27 L	1	2002	2002	11111	
14	669	28 E	1	2002	2002	669	
15	313	29 L	1	2002	2002	669	
15	313	30 E	1	2002	2003	11111	
15	313	31 E	1	2002	2003	313	
16	6682	32 L	7	2016	2016	11111	
16	6682	33 E	7	2016	2016	6682	
17	1378	34 L	2	2006	2006	11111	
17	1378	35 E	2	2006	2006	1378	
18	2135	36 L	3	2007	2007	11111	
18	2135	37 E	3	2007	2007	2135	
19	7239	38 L	8	2017	2017	11111	
19	7239	39 E	8	2017	2017	7239	
20	1034	40 L	2	2005	2005	11111	
20	1034	41 E	2	2005	2005	1034	

Tabla 4 -

RASTRO DEL ENCAMBIAMIENTO DE DISPERSION DE LAS  
DIRECCIONES DE LA LLAVE SECUNDARIA UNO

DIR.	SUB.	ACCESO		PARAMETROS		DIRECCIONES EN EL			DIR.
		NO	TI	DE CONTROL		ARCHIVO DE APUNTAJADORES			
TRO.	VE.	ME	PO	DIR	DIR	DIR	DIR	DIR	ARCH.
	UNO	NO		INI	FIN	ANT	ACT	SIG	PRIM.
1	B	1	E	2023	2023	2023	2023	2023	2007
2	33	2	F	2024	2024	2024	2024	2024	2018
3	B	3	E	2023	2023	2023	2023	2025	2001
3	B	4	E	2023	2023	2023	2025	2025	2009
4	24	5	E	2026	2026	2026	2026	2026	2018
5	82	6	E	2027	2027	2027	2027	2027	2020
6	35	7	E	2028	2028	2028	2028	2028	2008
7	67	8	E	2029	2029	2029	2029	2029	2004
8	92	9	E	2030	2030	2030	2030	2030	2012
9	20	10	E	2031	2031	2031	2031	2031	2010
10	20	11	E	2031	2031	2031	2031	2032	2010
10	20	12	E	2031	2032	2031	2032	2032	2014
11	66	13	E	2033	2033	2033	2033	2033	2011
12	74	14	E	2034	2034	2034	2034	2034	2019
13	13	15	E	2035	2035	2035	2035	2035	2013
14	97	16	E	2036	2036	2036	2036	2036	2002
15	30	17	E	2037	2037	2037	2037	2037	2003
16	24	18	E	2026	2026	2026	2026	2038	2013
16	24	19	E	2026	2038	2026	2038	2038	2016

Tabla 4.4

MASTRO DEL ENCADENAMIENTO DE DISPERSION DE LAS  
DIRECCIONES DE LA LLAVE SECUNDARIA LMO

RE	SUB	ALLESO	PARAMETROS		DIRECCIONES EN EL			DIA	
GIS	LLA	NO TI	DE CONTROL		ARCHIVO DE APUNTAJES			DEL	
TRO	VE	ME PO	DIR	DIR	DIR	DIR	DIR	ARCH.	
	LMO	NO	INI	FIN	ANI	ACT	SIG	PRIN.	
17	42	20	E	2039	2039	2039	2039	2039	2006
18	28	21	E	2040	2040	2040	2040	2040	2007
19	76	22	E	2041	2041	2041	2041	2041	2017
20	51	23	E	2042	2042	2042	2042	2042	2005

TABLA A.3

PASTREO DEL EMERENDAMIENTO DE DISPERSION DE LAS  
DIRECCIONES DE CALIDAD SECUNDARIA INDI

DIR	SUB	ACCESO	PARAMETROS		DIRECCIONES EN EL			DIR		
			DE CONTROL		ARCHIVO DE APUNTAOONES					
			DIR	DIR	DIR	DIR	DIR		DIR	
TRO	VE	ME	PO	INI	FIN	ANT	ACT	SIG	PRIN	
1	5	1	E	2043	2043	2043	2043	2043	2043	2001
2	8	2	E	2044	2044	2044	2044	2044	2044	2018
3	0	3	E	2045	2045	2045	2045	2045	2045	2009
4	4	4	E	2046	2046	2046	2046	2046	2046	2015
5	4	5	E	2046	2046	2046	2046	2047	2047	2015
5	4	6	E	2046	2047	2046	2047	2047	2047	2020
6	0	7	E	2045	2045	2045	2045	2048	2048	2009
6	0	8	E	2045	2048	2045	2048	2048	2048	2008
7	8	9	E	2044	2044	2044	2044	2049	2049	2018
7	8	10	E	2044	2049	2044	2049	2049	2049	2004
8	0	11	E	2045	2048	2045	2048	2050	2050	2008
8	0	12	E	2045	2050	2045	2050	2050	2050	2012
9	1	13	E	2051	2051	2051	2051	2051	2051	2010
10	7	14	E	2052	2052	2052	2052	2052	2052	2014
11	2	15	E	2053	2053	2053	2053	2053	2053	2011
12	3	16	E	2054	2054	2054	2054	2054	2054	2019
13	3	17	E	2054	2054	2054	2054	2055	2055	2019
13	3	18	E	2054	2055	2054	2055	2055	2055	2013
14	5	19	E	2043	2043	2043	2043	2056	2056	2001

TABLEAU 5

RASTREO DEL ENLACEAMIENTO DE DISPERION DE LAS  
DIRECCIONES DE LA CLAVE SECUNDARIA DOS

RE	SOL	ACCESO		CARRERILLOS		DIRECCIONES EN EL			DIR
		NO	TI	DE	CONTRAL	ARCHIVO DE APUNTAORES			
TRO	VE	NE	RO	DIR.	DIR	DIR.	DIR	DIR.	ARCH.
14	5	20	E	2043	2056	2043	2056	2056	2002
15	3	21	E	2054	2055	2054	2055	2057	2013
15	3	22	E	2054	2057	2055	2057	2057	2003
16	1	23	E	2051	2051	2051	2051	2058	2010
16	1	24	E	2051	2058	2051	2058	2058	2018
17	7	25	E	2052	2052	2052	2052	2059	2014
17	7	26	E	2052	2059	2052	2059	2059	2006
18	6	27	E	2060	2060	2060	2060	2065	2007
19	4	28	E	2066	2067	2066	2067	2061	2020
19	4	29	E	2066	2061	2067	2061	2061	2017
20	1	30	E	2051	2058	2051	2058	2062	2016
20	1	31	E	2051	2062	2058	2062	2062	2005

\*\*\*\*\*  
ERRORES DELECTADRE DURANTE LA DISPERSION DE REGISTROS  
\*\*\*\*\*

- 1 Metodo de dispersion por interpolacion lineal
  - 2 Metodo de dispersion por interpolacion de Lagrange
  - 3 Metodo de dispersion por suma y permutacion
- \*\*\*\*\*

Que metodo de dispersion desea ? 2

\*\*\*\*\*  
DISPERSION EN ARCHIVO POR INTERPOLACION DE LAGRANGE

DISPERSION EN SOBREFLEDO POR INTERPOLACION LINEAL  
\*\*\*\*\*

\*\*\*\*\*  
ESTADISTICAS DE LA DISPERSION DE REGISTROS  
\*\*\*\*\*

REGISTROS LEIDOS	20
REGISTROS DISPERSADOS	40
TOTAL COLISIONES	1
NUMERO DE ACCESOS	40
NUMERO DE ACCESOS PROMEDIO	2.0500E+00

\*\*\*\*\*

ESTADÍSTICAS DE LA DISPERSIÓN DE REGISTROS

\*\*\*\*\*

DISPERSADOS EN ÁREA NORMAL	20
EN PRIMER INTENTO	19
EN SEGUNDO INTENTO	1
EN TERCER INTENTO	0
EN CUARTO INTENTO	0
EN QUINTO INTENTO	0
DISPERSADOS EN AREA DE SOBREFLUJO	0
EN SEXTO INTENTO	0
EN SEPTIMO INTENTO	0
EN OCTAVO INTENTO	0
EN NOVENO INTENTO	0
EN DECIMO INTENTO	0
DISPERSADOS EN AREA ESPECIAL DE SOBREFLUJO	0
EN ONCEAVO INTENTO	0
EN DOCEAVO INTENTO	0
EN TRECEAVO INTENTO	0
EN CATORCEAVO INTENTO	0
EN QUINCEAVO INTENTO	0

ESTADÍSTICAS DE LA DISPERSIÓN DE REGISTROS

COLISIONES EN AREA NORMAL 1  
EN PRIMER INTENTO 1  
EN SEGUNDO INTENTO 0  
EN TERCER INTENTO 0  
EN CUARTO INTENTO 0  
EN QUINTO INTENTO 0  
COLISIONES EN AREA DE SOBREFLUJO 0  
EN SEXTO INTENTO 0  
EN SEPTIMO INTENTO 0  
EN OCTAVO INTENTO 0  
EN NOVENO INTENTO 0  
EN DECIMO INTENTO 0  
COLISIONES EN AREA ESPECIAL DE SOBREFLUJO 0  
EN ONCEAVO INTENTO 0  
EN DOCEAVO INTENTO 0  
EN TRECEAVO INTENTO 0  
EN CATORCEAVO INTENTO 0  
EN QUINCEAVO INTENTO 0

ESO ES TODO EN CUANTO A DISPERSION DE REGISTROS

TABLA n.º 6

PARAMETROS DE CONTROL DEL ARCHIVO DIRECTO DE APUNTAORES DE LA SUBLLAVE UNO

SUBLLAVE	DIRECCION	
	INICIAL	FINAL
8	2023	2025
13	2035	2035
20	2031	2037
24	2026	2038
28	2040	2040
30	2037	2037
33	2024	2024
35	2028	2028
42	2039	2039
51	2042	2042
61	2029	2029
76	2034	2034
76	2041	2041
82	2027	2027
84	2033	2033
92	2030	2030
97	2036	2036

TABLE A 7

PARAMETROS DE CONTROL DEL ARCHIVO DIRECTO DE PLANTACIONES DE LA SUBLAJE 205

SUBLAJE	DIRECCION	
	INICIAL	FINAL
0	2041	2050
1	2051	2062
2	2063	2073
3	2074	2087
4	2088	2091
5	2092	2096
6	2097	2098
7	2099	2099
8	2044	2049
9	11111	11111

Tabla 4.8

ARCHIVO DIRECTO PRINCIPAL

ESTA TESIS NO DEBE  
SALIR DE LA BIBLIOTECA

SIGLO	CLAVE	SUBCLAVE	SUBCLAVE	OTRO
	PRINCIPAL	uno	dos	DATO
2001	198	8	5	H
2002	469	97	5	H
2003	313	50	3	H
2004	870	67	8	H
2005	1034	51	1	H
2006	1378	42	7	H
2007	2135	28	8	H
2008	2620	51	0	H
2009	2795	8	0	H
2010	3434	20	1	H
2011	3670	64	2	H
2012	4650	92	0	H
2013	4837	13	1	H
2014	5851	20	1	H
2015	6221	24	4	H
2016	6682	24	8	H
2017	7019	76	4	H
2018	7624	33	8	H
2019	7781	74	3	H
2020	8218	82	4	H
2021	11111	11111	11111	
2022	11111	11111	11111	

TABLA 9

ARCHIVO DIRECTO PRINCIPAL

DIRECCION	LLAVE	SUBLLAVE	SUBLLAVE	OTRO
	PRINCIPAL	OTRO	OTRO	OTRO
2063	11111	11111	11111	
2064	11111	11111	11111	
2065	11111	11111	11111	
2066	11111	11111	11111	
2067	11111	11111	11111	
2068	11111	11111	11111	
2069	11111	11111	11111	
2070	11111	11111	11111	
2071	11111	11111	11111	
2072	11111	11111	11111	
2073	11111	11111	11111	
2074	11111	11111	11111	
2075	11111	11111	11111	
2076	11111	11111	11111	
2077	11111	11111	11111	
2078	11111	11111	11111	
2079	11111	11111	11111	
2080	11111	11111	11111	
2081	11111	11111	11111	
2082	11111	11111	11111	

Tabla 4.10

ARCHIVO DIRECTO CON LOS APUNTAORES DE LA SUBLAYE UNO

DIRECCION ANTERIOR	DIRECCION ACTUAL	DIRECCION SIGUIENTE	SUBLAYE	DIRECCION PRINCIPAL
2023	2023	2023	8	2031
2024	2024	2024	53	2018
2025	2025	2025	8	2009
2026	2026	2026	24	2015
2027	2027	2027	52	2020
2028	2028	2028	35	2006
2029	2029	2029	67	2004
2030	2030	2030	92	2012
2031	2031	2031	20	2010
2033	2032	2032	20	2014
2033	2033	2033	84	2011
2034	2034	2034	74	2019
2035	2035	2035	13	2015
2036	2036	2036	97	2002
2037	2037	2037	30	2003
2026	2038	2038	24	2016
2039	2039	2039	42	2006
2040	2040	2040	28	2007
2041	2041	2041	76	2017
2042	2042	2042	51	2005

TABLA 4-11

## ARCHIVO DIRECTO CON LOS APUNTADORES DE LA SUBLAVE: BOS

DIRECCION ANTERIOR	DIRECCION ACTUAL	DIRECCION SIGUIENTE	SUBLAVE	DIRECCION PRINCIPAL
2043	2043	2056	5	2001
2044	2044	2049	8	2018
2045	2045	2048	0	2009
2046	2046	2047	4	2015
2046	2047	2061	4	2020
2045	2048	2050	0	2008
2044	2049	2049	8	2004
2048	2050	2050	0	2012
2051	2051	2058	1	2010
2052	2052	2059	7	2014
2053	2053	2053	2	2011
2054	2054	2055	5	2019
2054	2055	2057	3	2013
2043	2056	2056	5	2002
2055	2057	2057	3	2003
2051	2058	2062	1	2016
2052	2059	2059	7	2006
2060	2060	2060	6	2007
2061	2061	2061	4	2017
2058	2062	2062	1	2005

TABLA 4.12

RASTREO DEL ACCESO DE LA LLAVE PRINCIPAL

RE	LLAVE	ACCESO	IN	DIRECCIÓN	CANPO	TIPO	
TRQ	PRIN	NO. FE	TEM	CALCU	ACCE	SOBRE	
	CIPAL	ME. PD	VALG	LARA	SADA	PRINCI	FLUJO
1	198	1 L	1	2001	2001	198	
2	7624	1 L	8	2018	2018	7624	
3	2795	1 L	5	2009	2009	2795	
4	6221	1 L	7	2015	2015	6221	
5	8218	1 L	9	2020	2020	8218	
6	2620	1 L	3	2008	2008	2620	
7	870	1 L	1	2004	2004	870	
8	4650	1 L	5	2012	2012	4650	
9	3414	1 L	4	2010	2010	3414	
10	5851	1 L	6	2014	2014	5851	
11	3670	1 L	4	2011	2011	3670	
12	7783	1 L	8	2019	2019	7783	
13	4837	1 L	5	2013	2013	4837	
14	469	1 L	1	2002	2002	469	
15	313	1 L	1	2002	2002	469	
15	313	2 L	1	2002	2003	313	
16	6682	1 L	7	2016	2016	6682	
17	1378	1 L	2	2006	2006	1378	
18	2135	1 L	3	2007	2007	2135	
19	7239	1 L	8	2017	2017	7239	
20	1034	1 L	2	2005	2005	1034	

TABLA 4.33

RASTRO DEL ENCADENAMIENTO DE ACCESO DE LAS

DIRECCIONES DE LA LLAVE SECUNDARIA. UNO

RE	SUB	ACCESO	ARCHIVO DE APUNTAORES			ARCHIVO PRINCIPAL		
			DIR.	DIR.	DIR.	LLAVE	SUB	OTRO
TRO	UNO	RE PO	ACC.	SIG.	ARCH.	PRIN	LLAVE	DATO
		NO			PRIN.	CIPAL	BOB	
1	8	2 L	2023	2025	2001	148	5	H
2	8	4 L	2025	2025	2009	2795	0	H
3	13	2 L	2035	2035	2013	4837	3	H
4	20	2 L	2031	2032	2010	3414	1	H
5	20	4 L	2032	2032	2014	5855	7	H
6	24	2 L	2026	2038	2015	6221	4	H
7	24	4 L	2038	2038	2018	6682	1	H
8	28	2 L	2040	2040	2007	2135	6	H
9	30	2 L	2037	2037	2003	313	3	H
10	33	2 L	2024	2024	2018	7624	8	H
11	35	2 L	2028	2028	2008	7420	0	H
12	42	2 L	2039	2039	2004	1338	7	H
13	51	2 L	2042	2042	2001	1034	1	H
14	67	2 L	2029	2029	2004	870	8	H
15	74	2 L	2034	2034	2011	7783	3	H
16	76	2 L	2043	2043	2017	7249	4	H
17	82	2 L	2027	2027	2020	8218	4	H
18	84	2 L	2033	2033	2011	3670	2	H
19	92	2 L	2030	2030	2012	4450	0	H

TABLE 4.11

RASTRO DEL ENLAZAMIENTO DE ACCESO DE LAS

DIRECCIONES DE LA LLAVE SECUNDARIA UNO

RE	SUB	ACCESO	ARCHIVO DE APUNTAORES			ARCHIVO PRINCIPAL		
			DIR	DIR	DIR	LLAVE	SUB	OTRO
TRD	UNO	ME PO	ACT	SIG	ARCH	PRIN	LLAVE	DATA
		NO			PRIN	PRIN	DOS	
20	97	2 1	2036	2036	2002	469	5	R

Tabla 4. 14.

RASTRO DEL ENCADENAMIENTO DE ACCESO DE LAS

DIRECCIONES DE LA LLAVE SECUNDARIA: DOS

NO	SUB LLAVE	ACCESO		ARCHIVO DE APUNTAJONES			ARCHIVO PRINCIPAL		
		NU	TI	DIR	DIR	DIR	LLAVE	SUB	OTRO
TRO	DOS	ME	PO	ACT	SIG	ARCH	PRIN	LLAVE	DATO
		NO				PRIN	CIPAL	UNO	
1	0	2	L	2043	2048	2009	2795	8	N
2	0	4	L	2048	2050	2008	2620	35	N
3	0	6	L	2050	2050	2012	4650	92	N
4	1	2	L	2093	2098	2010	5414	20	N
5	1	4	L	2098	2062	2016	6682	24	N
6	1	6	L	2062	2062	2005	1034	51	N
7	2	2	L	2053	2053	2011	3670	84	N
8	3	2	L	2054	2055	2019	7783	74	N
9	3	4	L	2055	2057	2013	4837	13	N
10	3	6	L	2057	2057	2003	113	30	N
11	4	2	L	2046	2047	2015	6271	24	N
12	4	4	L	2047	2051	2020	8218	82	N
13	4	6	L	2061	2061	2017	7234	76	N
14	5	2	L	2043	2054	2007	198	8	N
15	5	4	L	2056	2056	2002	469	97	N
16	6	2	L	2060	2060	2007	2133	28	N
17	7	2	L	2052	2054	2014	5851	20	N
18	7	4	L	2059	2059	2006	1378	42	N
19	8	2	L	2044	2049	2018	7624	33	N

TABLA 4 1a

RASTRO DEL ENCADENAMIENTO DE ACCESO DE LAS

DIRECCIONES DE LA LLAVE SECUNDARIA: GOS

Nº	ARCHIVO		ARCHIVO DE APUNTAORES			ARCHIVO PRINCIPAL		
	LLAVE	NUM	DIP	DIP	DIP	LLAVE	SUB	CIRCO
TRQ	DOA	ME PO	ACT	SIG	ARCH	PRIN	LLAVE	DATO
		BO			PRIN	CIPAL	UNO	
20	B	4 L	2069	2069	2004	870	67	H

\*\*\*\*\*  
 ERRORES DETECTADOS DURANTE EL ACCESO DE REGISTROS  
 \*\*\*\*\*

- \*\*\*\*\*
- 1 Metodo de acceso por interpolación lineal
  - 2 Metodo de acceso por interpolación de Lagrange
  - 3 Metodo de acceso por suma y por división
- \*\*\*\*\*

Que método de acceso desea ? 2

\*\*\*\*\*

ACCESO EN ARCHIVO POR INTERPOLACION DE LAGRANGE

ACCESO EN SOBRELLENO POR INTERPOLACION LINEAL

\*\*\*\*\*

\*\*\*\*\*

ESTADISTICAS DEL ACCESO DE REGISTROS

\*\*\*\*\*

REGISTROS LEIDOS: 20

REGISTROS LOCALIZADOS: 20

TOTAL COLISIONES: 1

NUMERO DE ACCESOS: 21

NUMERO DE ACCESOS PROMEDIO: 1.0500E+00

ESTADÍSTICAS DEL ALFENO DE REGISTROS

ACCESADOS EN AREA NORMAL	20
EN PRIMER INTENTO	19
EN SEGUNDO INTENTO	1
EN TERCER INTENTO	0
EN CUARTO INTENTO	0
EN QUINTO INTENTO	0
ACCESADOS EN AREA DE SOBREFLUJO	0
EN SEXTO INTENTO	0
EN SEPTIMO INTENTO	0
EN OCTAVO INTENTO	0
EN NOVENO INTENTO	0
EN DECIMO INTENTO	0
ACCESADOS EN AREA ESPECIAL DE SOBREFLUJO	0
EN ONCEAVO INTENTO	0
EN DOCEAVO INTENTO	0
EN TRECEAVO INTENTO	0
EN CATORCEAVO INTENTO	0
EN QUINCEAVO INTENTO	0

ESTADÍSTICAS DEL ACCESO DE REGISTROS

```

*****
COLISIONES EN AREA NORMAL      1
    EN PRIMER INTENTO          1
    EN SEGUNDO INTENTO         0
    EN TERCER INTENTO          0
    EN CUARTO INTENTO          0
    EN QUINTO INTENTO          0

COLISIONES EN AREA DE SOBREFUJO 0
    EN SEXTO INTENTO           0
    EN SEPTIMO INTENTO         0
    EN OCHOVO INTENTO          0
    EN NOVENO INTENTO          0
    EN DECIMO INTENTO          0

COLISIONES EN AREA ESPECIAL DE SOBREFUJO 0
    EN ONCEAVO INTENTO         0
    EN DOCEAVO INTENTO         0
    EN TRECEAVO INTENTO        0
    EN CATORCEAVO INTENTO      0
    EN QUINCEAVO INTENTO       0
  
```

\*\*\*\*\*

ESO ES TODO EN CUANTO A ACCESO DE REGISTROS

\*\*\*\*\*

TABLA 4 15

REGISTRO DEL ACCESO DE LA LLAVE PRINCIPAL

NO	LLAVE	ACCESO	IN	DIRECCION		CAMPO	TIPO
015	PRIN	MU TI	TER	JALCO	ARTE	LLAVE	SOBRE
TR0	LOCAL	ME PO	VALD	LADA	SALA	PRINCI	PLUJO
1	469	1 L	1	2002	2002	469	

TABLA 4 16

REGISTRO DEL ACCESO DE LA LLAVE PRINCIPAL 7624

NO	LLAVE	ACCESO	IN	DIRECCION		CAMPO	TIPO
015	PRIN	MU TI	TER	JALCO	ARTE	LLAVE	SOBRE
TR0	PRIN	ME PO	VALD	LADA	SALA	PRINCI	PLUJO
1	7624	1 L	1	2018	2018	7624	

TABLA 4.17

RASTRO DEL ACCESO DE LA LLAVE PRINCIPAL 6666

RE	LLAVE	ACCESO	IN	DIRECCION		CANPO	TIPO
GIS	PRIN	MJ T1	TER	CALCU	ACCE	LLAVE	SOBRE
TRO	LIPAL	ME PO	VALO	LADA	SADA	PRINCI	FLUJO
1	6666	1 L	7	2016	2016	6662	
1	6666	2 L	7	2021	2021	11111	1
1	6666	3 L	7	2021	2022	11111	1
1	6666	4 L	7	2075	2075	11111	2
1	6666	5 L	7	2075	2076	11111	2
1	6666	6 L	7	2075	2076	11111	2
1	6666	7 L	7	2075	2077	11111	2
1	6666	8 L	7	2075	2073	11111	2

TABLA 4.18

RASTRO DEL ENCADENAMIENTO DE ACCESO DE LAS

DIRECCIONES DE LA LLAVE SECUNDARIA UNO 20

RE	SUB	ACCESO		ARCHIVO DE APUNTAORES			ARCHIVO PRINCIPAL		
		NO	TJ	DIR	DIR	DIR	LLAVE	SUB	OTRO
TRD	UNO	RE	PO	ACT	SIG	ARCH	PRIN	LLAVE	DATO
		RO				PRIN	CIPAL	DOS	
1	20	2	L	2031	2032	2010	3414	1	H
2	20	4	L	2032	2032	2014	5851	7	H

TABLA 4.19

RASTRO DEL ENCADENAMIENTO DE ACCESO DE LAS

DIRECCIONES DE LA LLAVE SECUNDARIA UNO 24

RE	SUB	ACCESO		ARCHIVO DE APUNTAORES			ARCHIVO PRINCIPAL		
		NO	TJ	DIR	DIR	DIR	LLAVE	SUB	OTRO
TRD	UNO	RE	PO	ACT	SIG	ARCH	PRIN	LLAVE	DATO
		RO				PRIN	CIPAL	DOS	
1	24	2	L	2026	2038	2015	6221	4	H
2	24	4	L	2038	2038	2016	6682	1	H

Tabla 4 20

MAPA DEL ENLACE DE ACCESO DE LAS  
DIRECCIONES DE LA CLAVE SECUNDARIA DOS 4

RE	SUB	ACCESO		ARCHIVO DE APUNTAJOS			ARCHIVO PRINCIPAL		
		MI	TI	SIG	DIV	DIV	LLAVE	SUB	OTRO
TRD	DOS	ME	PD	ACT	SIG	ARCH	PRIN	LLAVE	BATO
		RD				PRIN	CIPAL	UMC	
1	4	2	L	2046	2047	2015	6221	24	H
2	4	4	L	2047	2041	2020	6218	82	H
3	4	6	L	2061	2061	2017	7239	76	H

Tabla 4 21

MAPA DEL ENLACE DE ACCESO DE LAS  
DIRECCIONES DE LA CLAVE SECUNDARIA DOS 6

RE	SUB	ACCESO		ARCHIVO DE APUNTAJOS			ARCHIVO PRINCIPAL		
		MI	TI	SIG	DIV	DIV	LLAVE	SUB	OTRO
TRD	DOS	ME	PD	ACT	SIG	ARCH	PRIN	LLAVE	BATO
		RD				PRIN	CIPAL	UMC	
1	6	2	L	2060	2060	2007	2135	28	H

\*\*\*\*\*  
BASES DE LA CORRIERA INTERACTIVA DE ACCESO INDIVIDUAL  
\*\*\*\*\*

1. Método de acceso por interpolación spline
  2. Método de acceso por interpolación de Lagrange
  3. Método de acceso por suma y interpolación
- \*\*\*\*\*

QUE MÉTODO DE ACCESO DESEA ? 2

\*\*\*\*\*  
ACCESO EN APOLINIA POR INTERPOLACION DE LAGRANGE

ACCESO EN SOBREFUOCO POR INTERPOLACION LINEAL  
\*\*\*\*\*

\*\*\*\*\*  
1 LOCALIZAR CLAVE PRINCIPAL

2 LOCALIZAR SUBCLAVE UNO

3 LOCALIZAR SUBCLAVE DOS  
\*\*\*\*\*

QUE TIPO DE CLAVE DESEA LOCALIZAR ? 1

(CLAVE PRINCIPAL) A LOCALIZAR ? 449

DESEA CONTINUAR EN ESTO ? \*

\*\*\*\*\*

1 LOCALIZAR CLAVE PRINCIPAL

2 LOCALIZAR SUBCLAVE UNO

3 LOCALIZAR SUBCLAVE DOS

\*\*\*\*\*

QUE TIPO DE LLAVE DESEA LOCALIZAR ? \*

LLAVE PRINCIPAL A LOCALIZAR ? 7624

DESEA CONTINUAR EN ESTO ? \*

\*\*\*\*\*

1 LOCALIZAR CLAVE PRINCIPAL

2 LOCALIZAR SUBCLAVE UNO

3 LOCALIZAR SUBCLAVE DOS

\*\*\*\*\*

QUE TIPO DE LLAVE DESEA LOCALIZAR ? \*

LLAVE PRINCIPAL A LOCALIZAR ? 6666

\*\*\*\*\*

EN ESTA SE DEBE MARCAR LA LLAVE DESDE

\*\*\*\*\*

DESEA CONTINUAR CON EL ?

\*\*\*\*\*

1 LOCALIZAR LLAVE PRINCIPAL

2 LOCALIZAR SOBRELAVE UNO

3 LOCALIZAR SOBRELAVE DOS

\*\*\*\*\*

QUE TIPO DE LLAVE DESEA LOCALIZAR ?

SOBRELAVE UNO A LOCALIZAR ?

DESEA CONTINUAR CON EL ?

\*\*\*\*\*  
1 LOCALIZAR LLAVE PRINCIPAL  
2 LOCALIZAR SUBLLAVE UNO  
3 LOCALIZAR SUBLLAVE DOS  
\*\*\*\*\*

QUE TIPO DE LLAVE DESEA LOCALIZAR ? 2

SUBLLAVE UNO A LOCALIZAR ? 24

BASEA CONTINUAR (S/N) ? S

\*\*\*\*\*  
1 LOCALIZAR LLAVE PRINCIPAL  
2 LOCALIZAR SUBLLAVE UNO  
3 LOCALIZAR SUBLLAVE DOS  
\*\*\*\*\*

QUE TIPO DE LLAVE DESEA LOCALIZAR ? 2

SUBLLAVE UNO A LOCALIZAR ? 66

\*\*\*\*\*  
NO ESTÁ EN EL ARCHIVO LA SUBLAVE UNO 00

\*\*\*\*\*

DESEA CONTINUAR (S/N) ? 0

\*\*\*\*\*

1 LOCALIZAR CLAVE PRINCIPAL

2 LOCALIZAR SUBLAVE UNO

3 LOCALIZAR SUBLAVE DOS

\*\*\*\*\*

QUE TIPO DE CLAVE DESEA LOCALIZAR ? 3

SUBLAVE DOS A LOCALIZAR ? 4

DESEA CONTINUAR (S/N) ? 0

\*\*\*\*\*

- 1 LOCALIZAR LLAVE PRINCIPAL
- 2 LOCALIZAR SUBLAVE UNO
- 3 LOCALIZAR SUBLAVE DOS

\*\*\*\*\*

QUE TIPO DE LLAVE DESEA LOCALIZAR ? 3

SUBLAVE DOS A LOCALIZAR ? 6

DESEA CONTINUAR (s/n) ? 0

\*\*\*\*\*

- 1 LOCALIZAR LLAVE PRINCIPAL
- 2 LOCALIZAR SUBLAVE UNO
- 3 LOCALIZAR SUBLAVE DOS

\*\*\*\*\*

QUE TIPO DE LLAVE DESEA LOCALIZAR ? 3

SUBLAVE DOS A LOCALIZAR ? 9

\*\*\*\*\*  
NO ESTA EN EL ARCHIVO LA SUBCLAVE DOS. R  
\*\*\*\*\*

DESEA CONTINUAR (q/n) ? n

\*\*\*\*\*  
ESO ES TODO EN CUANTO A ACCESO DE REGISTROS  
\*\*\*\*\*  
\*\*\*\*\*  
FRASES DE TELAFIOS DURANTE EL ACCESO INDIVIDUAL DE REGISTROS  
\*\*\*\*\*

## CONCLUSIONES

Las primeras conclusiones se harán en base a las siguientes estadísticas generadas a partir de 20 archivos de 100 registros generados en forma aleatoria cada uno y dispersados y accedidos con los tres algoritmos de dispersión que se diseñaron en el capítulo 3.2: interpolación lineal, interpolación de Lagrange de segundo orden y suma-división respectivamente.

Las estadísticas se presentan por grupos de 3 renglones; el primer renglón corresponde a la interpolación lineal, el segundo a la interpolación de Lagrange de segundo orden y el tercer renglón se refiere al algoritmo de suma-división.

La columna PAR representa el número promedio de accesos por registro.

La columna AA indica el número de registros accedidos en el primer intento, es decir, los registros que se accedieron sin ninguna colisión.

La columna BR indica el número de accesos que se hicieron en el archivo directo principal.

La columna CC indica el número de accesos que se hicieron en el área de sobreflujo del archivo directo principal.

La columna DD indica el número de accesos que se hicieron en el archivo directo de sobreflujo especial.

La columna EE indica el número de colisiones que se presentaron en el archivo directo principal.

La columna FF indica el número de colisiones que se presentaron en el área de sobreflujo del archivo directo principal.

La columna GG indica el número de colisiones que se presentaron en el archivo directo principal.

ESTADÍSTICAS DE ACCESOS DE RESISTENCIA

ARREST	NUM	NUM	NUM	PAR	AA	ACCESOS			COLISIONES		
						BN	LT	DD	EE	EE	OO
1	100	100	200	2 00	66	89	9	2	85	15	0
1	100	78	178	1 78	67	93	6	1	72	6	0
1	100	114	214	2 14	60	88	10	2	96	18	0
2	100	77	177	1 77	67	93	5	2	69	8	0
2	100	70	170	1 70	63	95	5	0	69	1	0
2	100	75	175	1 75	66	92	8	0	71	4	0
5	100	114	214	2 14	65	87	9	6	86	27	1
5	100	87	187	1 87	70	92	7	1	79	8	0
5	100	94	194	1 94	62	90	8	2	78	16	0
4	100	92	192	1 92	62	89	10	1	79	13	0
4	100	73	173	1 73	64	92	7	1	65	8	0
4	100	105	205	2 05	63	88	8	4	89	16	0
5	100	92	192	1 92	64	89	9	2	82	10	0
5	100	86	186	1 86	63	93	6	1	80	6	0
5	100	87	187	1 87	64	91	9	0	79	8	0
6	100	107	207	2 07	64	90	7	3	90	17	0
6	100	69	169	1 69	68	93	7	0	67	2	0
6	100	125	225	2 25	59	86	9	5	95	30	0

ARCHI	NUM	NUM	NUM	PAR	AA	ACCESOS			DECISIONES		
						80	81	82	83	84	85
7	100	76	176	1 76	68	92	8	0	70	6	0
7	100	63	163	1 63	61	95	5	0	62	1	0
7	100	77	177	1 77	65	93	7	0	77	0	0
8	100	99	199	1 99	61	91	8	1	89	10	0
8	100	78	178	1 78	61	94	6	0	76	2	0
8	100	91	191	1 91	62	92	8	0	86	5	0
9	100	87	187	1 87	64	91	8	1	78	9	0
9	100	66	166	1 66	70	95	1	0	65	1	0
9	100	110	210	2 10	64	89	7	4	83	27	0
10	100	79	179	1 79	73	90	8	2	66	13	0
10	100	48	148	1 48	78	95	1	0	48	0	0
10	100	81	181	1 81	66	90	8	2	65	16	0
11	100	103	203	2 03	66	89	6	1	81	20	0
11	100	92	192	1 92	66	91	7	2	81	11	0
11	100	65	165	1 65	65	95	5	0	64	1	0
12	100	95	195	1 95	64	93	7	2	82	13	0
12	100	68	168	1 68	69	95	5	0	63	5	0
12	100	74	174	1 74	65	92	7	1	64	10	0

ACR#	NUM	NUM	NUM	FAR	EA	ACCESS			EVIDENCE		
						BB	CT	DB	EE	FF	GG
13	100	77	177	1 77	64	88	9	3	83	18	0
13	100	78	178	1 78	66	92	8	0	75	3	0
13	100	87	187	1 87	62	92	8	0	85	2	0
14	100	84	184	1 84	67	91	9	0	74	10	0
14	100	70	170	1 70	64	94	6	0	69	1	0
14	100	96	196	1 96	60	89	9	2	81	15	0
15	100	75	175	1 75	64	93	7	0	71	4	0
15	100	63	163	1 63	67	96	4	0	62	1	0
15	100	107	207	2 07	64	90	8	2	89	18	0
16	100	101	201	2 01	66	88	7	5	78	22	1
16	100	75	175	1 75	70	91	7	2	67	8	0
16	100	87	187	1 87	66	90	9	1	79	8	0
17	100	96	196	1 96	58	90	10	0	88	8	0
17	100	75	175	1 75	65	91	6	0	72	3	0
17	100	92	192	1 92	62	89	10	1	82	10	0
18	100	88	188	1 88	66	90	9	1	79	9	0
18	100	75	175	1 75	65	93	7	0	72	3	0
18	100	80	180	1 80	67	90	8	2	70	10	0

ESTADÍSTICAS DEL ACCESO DE REGISTROS

ARCHI	NUM	NUM	NUM	PAR	AA	ACCESOS			SOLUCIONES		
						BB	CC	DD	EE	FF	GG
NO	REG	LOC	ACC								
19	100	111	211	2 11	58	89	6	3	89	22	0
19	100	87	187	1 87	68	91	7	2	73	14	0
19	100	91	191	1 91	63	92	7	1	64	9	0
20	100	79	179	1 79	67	91	7	2	64	15	0
20	100	58	158	1 58	70	95	5	0	54	4	0
20	100	100	200	2 00	67	87	9	4	75	25	0

PROMEDIOS DE LAS ESTADÍSTICAS DEL ACCESO DE REGISTROS

NUM	NUM	NUM	PAR	AA	ACCESOS			SOLUCIONES		
					BB	CC	DD	EE	FF	GG
REG	LOC	ACC								
100	92 70	192 70	1 927	64 70	90 05	6 30	1 85	79 15	13 45	0 10
100	72 95	172 95	1 729	60 75	93 05	6 04	0 40	68 55	4 40	0 00
100	92 80	192 80	1 920	61 60	90 25	8 10	1 65	79 60	12 40	0 00

De las estadísticas anteriores se puede concluir que el mejor algoritmo de dispersión es el de interpolación de Lagrange de segundo orden debido a que se obtuvo

1) el promedio del número de colisiones más bajo 72.95.

2) el promedio del número total de accesos más bajo 172.95.

3) el promedio de accesos por registro más bajo PAR1 729.

4) el promedio del número de registros accedidos en el primer intento más alto: 67.15.

5) el promedio del número de registros accedidos en el archivo directo principal más alto: 95.45.

6) el promedio del número de registros accedidos en el área de sobreflujo del archivo directo principal más bajo

6.05.

7) el promedio del número de registros accedidos en el archivo directo de sobreflujo especial más bajo 0.50.

8) el promedio del número de colisiones en el archivo directo principal más bajo 68.55.

9) el promedio del número de colisiones en el área de sobreflujo del archivo directo principal más bajo 4.40.

10) el promedio del número de colisiones en el archivo directo de sobreflujo especial igual a cero.

De los valores de las tablas mostradas anteriormente podemos concluir que el algoritmo de dispersión por el método de interpolación de Lagrange de segundo orden resultó ser el mejor ya que se obtienen los valores más bajos en los parámetros evaluados. Siendo estos los más significativos en los archivos de acceso directo.

Entre menor sea el número de accesos para grabar o recuperar un registro el algoritmo de dispersión es mejor ya que lo realiza en un tiempo menor, lo cual es muy importante en los sistemas interactivos de tiempo real.

Este aspecto se conoce como "Tiempo de respuesta" siendo este el tiempo que transcurre desde que el usuario transmite su información y el procesador entrega la respuesta en la pantalla.

El mecanismo utilizado para la resolución de colisiones es el algoritmo de dispersión, solo que en este caso se utiliza un espacio de memoria más pequeño sin embargo un número menor de registros tienen necesidad de este espacio.

Por último los registros que no fueron grabados en este área y que son registros colisionados se graban en un espacio de memoria independiente el cual tiene la característica de ser secuencial. Sin embargo un número finito de registros requieren ser grabados en este área.

Se debe hacer mención que los valores obtenidos en las tablas resultan de la muestra de 100 registros grabados en el archivo de datos el cual fue dimensionado de acuerdo al volumen de registros de la muestra.

En un ambiente de operación real, el volumen de registros que se graban en los archivos deben ser estimados dejándose un margen del holgura del 20 por ciento de registros adicionales para un posible crecimiento.

Con este espacio se protege el archivo de una posible saturación y además la eficiencia del algoritmo de dispersión se mejora

En general podemos concluir que la herramienta desarrollada en este trabajo puede ser de gran utilidad en el desarrollo de sistemas que deban operar en un ambiente comercial en donde el tiempo de respuesta es un factor determinante

El manejador de archivos facilita el desarrollo de los programas al proporcionar el medio para el acceso a los archivos y el control de los mismos, este puede ser utilizado desde cualquier programa escrito en cualquier lenguaje de programación, reduciendo significativamente los tiempos de desarrollo y estandarizando la forma y el medio de acceso a los archivos

## APLICACIONES

La aplicación principal del manejador de archivos es facilitar al programador el acceso a archivos de tipo directo evitando tener que definir una función de dispersión y la resolución de colisiones llamando de una manera simple desde cualquier lenguaje de programación a la rutina de acceso.

El manejador de archivos puede ser utilizado en cualquier sistema que debe operar en un ambiente transaccional.

El sistema puede ser tan simple o complicado como sea necesario ya que esto dependerá de la propia aplicación en sí y no del manejador de archivos ya que este solo realiza la función de acceso y las operaciones de grabación y recuperación de datos y el acceso a los archivos.

El único requerimiento de la rutina es que debe correr en sistemas de cómputo en donde exista el recurso de archivos de acceso directo.

El manejador de archivos actúa como una subrutina cuando es llamado desde otro programa por esto es necesario que exista un área común entre el programa del usuario y la subrutina, esta área se llama área de enclavamiento y contiene los parámetros y datos que se pasan entre el programa principal y la subrutina.

Ejemplo de la definición del área de encadenamiento en un programa escrito en lenguaje COBOL.

LINKAGE-SECTION

```
01 AREA-DE-DATOS      PICTURE X(90)  área para el dato principal
01 PARAMETROS
03 OPERACION         PICTURE X(02)
03 NUMERO-DE-ARCHIVO PICTURE X(02)
03 CODIGO-DE-RETORNO PICTURE X(04)
```

Ejemplo de una llamada a la subrutina desde un programa de usuario:

```
CALL "ACCESO" USING AREA-DATOS PARAMETROS
```

En el área de datos se genera el registro que se va a insertar o a recuperar, el área de parámetros está constituida por la operación, número de archivo a acceder y código de retorno.

Las operaciones que se pueden realizar son:

- 01 inserta registro
- 02 recupera registro
- 03 modifica registro
- 04 borra registro

El código de retorno al inicio de la llamada lleva el mismo valor de la operación, cuando la operación no se realiza correctamente este tiempo es modificado por la subrutina con el código de error que indica el sistema operativo

#### Inserción

Esta operación tiene como objetivo insertar un nuevo registro dentro del archivo de datos así como en sus archivos de apuntadores. Su operación incluye la ejecución de la función de dispersión así como la resolución de colisiones, estas funciones se describen en otro capítulo. La operación de inserción determina a través de la tabla de localización de archivos el espacio de direcciones en el cual va a realizar la función de dispersión para escribir la llave principal y sus apuntadores.

En el archivo principal se graba el registro completo de datos de acuerdo a como está definido en el programa del usuario conservando el valor de la dirección física en donde se graba el dato. Esta dirección será utilizada para edicionarla en el apuntador.

#### Recuperación

Esta operación de la rutina realiza la recuperación del registro que fue grabado con anterioridad. Cuando se desea recuperar el dato por la llave principal esta operación la rutina realiza la función de dispersión y recupera el dato en caso de existir, si el dato no existe la rutina devuelve un estado de operación que indica que el dato no fue localizado.

#### Borrado

Mediante esta operación se realiza la baja lógica en los espacios de direcciones y apuntadores, esta operación se realiza mediante cambiar el valor de situación del apuntador de un cero a un uno. El uno en el campo de situación indica que el registro está dado de baja lógicamente, para realizar la baja física es necesario reorganizar el archivo leyendo todos los datos, clasificarlos y cargando nuevamente el archivo.

#### Modificación

Esta estructura consiste en acceder el espacio de direcciones principal para cambiar datos que no formen parte de la llave. Debido a que en esta operación no hay cambio en el valor de la llave, la dirección física del registro no se ve modificada al realizar un cambio en los datos.

#### Criterios para la asignación de espacio de archivos de acceso directo.

Los archivos de acceso directo son estáticos en su crecimiento, es decir que el espacio debe asignarse desde el inicio de su creación considerando el volumen de datos a grabar más el crecimiento que tendrá el archivo.

Es por esto que se debe ser muy cuidadoso para asignar el espacio de un archivo de acceso directo ya que este quedará fijo durante el uso del archivo o hasta que este sea reorganizado nuevamente.

Así también es importante considerar que asignar espacio que no va a ser utilizado es costoso para cualquier sistema de cómputo, ya que se están reservando de manera exclusiva recursos que no se van a utilizar.

Debido a que la función de dispersión depende directamente del valor de la llave de acceso, la cual tiene un comportamiento de tipo aleatorio, es posible que el espacio de direcciones quede con espacios o huecos que no fueron asignados por la función de dispersión de tal manera que siempre se debe considerar dar holgura al espacio de direcciones.

La asignación del espacio en disco para almacenar la información, es un aspecto importante cuando se diseña un sistema de acceso directo. Deben considerarse los siguientes criterios:

número de registros iniciales a almacenar

El analista deberá realizar un análisis de los datos que se van a grabar determinando el volumen inicial de registros de acuerdo al análisis de la información actual.

Crecimiento del Archivo.

Hacer un análisis para determinar en base a la frecuencia de uso de la información el número de registros que se incrementan en un periodo determinado de tiempo, después de este periodo se debe realizar una reorganización del archivo

Longitud del registro físico.

La longitud del registro físico ayuda a calcular el número de caracteres que se grabarán en el espacio de direcciones.

Ejemplo: dimensionamiento de un archivo de datos principal con tres claves.

Datos:

Registros físicos	1,000
Crecimiento en un mes	100
Longitud del registro	120 caracteres

Cálculo

Archivo directo principal:

1100 registro x 120 caracteres	=	132 000 caracteres
132 000 / 1024	=	128.90 kbytes

Área de sobreflujo del archivo directo principal:

10 % del archivo directo principal = 128.90 Kbytes / 10 = 12.89 Kbytes

Archivo directo de apuntadores para la subilva 1

1100 registros x longitud apuntador = 1100 x 9 = 9 900 caracteres

$$9\ 900 / 1024 = 9\ 67\ \text{Kbytes}$$

Archivo directo de apuntadores para la subilva 2

1100 registros x longitud apuntador = 1100 x 10 = 11 000 caracteres

$$11\ 000 / 1024 = 10\ 76\ \text{Kbytes}$$

Espacio total requerido:

Archivo directo principal 128.90 Kbytes

Área de sobreflujo del archivo directo principal 12.89 Kbytes

Archivo directo de apuntadores para la subilva 1 9.67 Kbytes

Archivo directo de apuntadores para la subilva 2 10.76 Kbytes

-----  
total requerido 162.20 Kbytes

**BIBLIOGRAPHIA**

**Computer data base organization**

James Martin

Adison Wesley

QA76 .M324

**Advanced database techniques**

Daniel Martin

Massachusetts Institute of Technology, 1986

QA76 .V D3m33

**File organization for database design**

Go Wiederhold

McGraw-Hill, 1987

QA76 .9F5 W54

**An introduction to data structures with applications**

Ivan Paul Tremblay, Paul G. Sorenson

McGraw-Hill, 1984

QA76 .V T35173