


# Procesadores de Lenguaje

## Generación de código intermedio



**Cristina Tirnauca**

**Domingo Gómez Pérez**

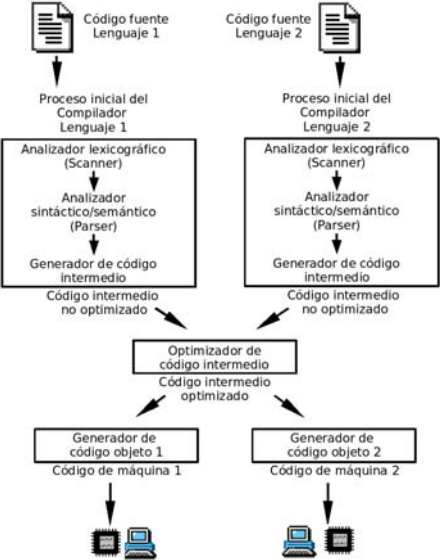
DPTO. DE MATEMÁTICAS,  
ESTADÍSTICA Y COMPUTACIÓN

Este tema se publica bajo Licencia:

[Creative Commons BY-NC-SA 3.0](https://creativecommons.org/licenses/by-nc-sa/3.0/)

# Recordemos

Fuente: Wikipedia



# Lenguajes de Programación Involucrados

Incluso antes de analizar cómo es el compilador por dentro

Hay que tener presentes no menos de tres lenguajes:

- ▶ El lenguaje **fuelle** en que estarán escritos los programas a compilar;
- ▶ el lenguaje **objeto** (ejecutable o interpretable) en que estarán “escritos” los programas compilados;

# Lenguajes de Programación Involucrados

Incluso antes de analizar cómo es el compilador por dentro

Hay que tener presentes no menos de tres lenguajes:

- ▶ El lenguaje **fuelle** en que estarán escritos los programas a compilar;
- ▶ el lenguaje **objeto** (ejecutable o interpretable) en que estarán “escritos” los programas compilados;
- ▶ el lenguaje en que está “escrito” **el compilador**.

# Lenguajes de Programación Involucrados

Incluso antes de analizar cómo es el compilador por dentro

Hay que tener presentes no menos de tres lenguajes:

- ▶ El lenguaje **fuelle** en que estarán escritos los programas a compilar;
- ▶ el lenguaje **objeto** (ejecutable o interpretable) en que estarán “escritos” los programas compilados;
- ▶ el lenguaje en que está “escrito” **el compilador**.

Cuando miramos dentro del compilador, las cosas se complican:

- ▶ Lenguajes de especificación de analizadores y gramáticas,
- ▶ códigos intermedios. . .

Una técnica útil: **diagramas en T**.

# Código Intermedio

En acción

## Códigos de tres direcciones

- ▶ Cada orden son funciones de dos registros;
- ▶ solo se puede utilizar tipos básicos, no hay funciones y todo el código se realiza por bloques;
- ▶ la gestión de memoria se realiza en el código;

Tendremos que afrontar algunas cuestiones:

- ▶ **Gestión de etiquetas** para implementar mediante saltos condicionales o incondicionales las estructuras de control (“mientras”).
- ▶ **Tabla de símbolos:**
  - ▶ comprobar las reglas sobre declaraciones de identificadores;
  - ▶ asociar, a cada identificador que encontramos en “tiempo de compilación”, la memoria que le corresponderá en “tiempo de ejecución”.

# Lenguaje Fuente

Ingredientes que distinguen unos de otros

Aspectos a considerar:

1. Estructuras de control;
2. Expresiones;
3. Tipos básicos;
4. Tipos estructurados:

# Lenguaje Fuente

Ingredientes que distinguen unos de otros

## Aspectos a considerar:

1. Estructuras de control;
2. Expresiones;
3. Tipos básicos;
4. Tipos estructurados:
  - ▶ tamaño fijo,
  - ▶ tamaño variable;



# Lenguaje Fuente

Ingredientes que distinguen unos de otros

## Aspectos a considerar:

1. Estructuras de control;
2. Expresiones;
3. Tipos básicos;
4. Tipos estructurados:
  - ▶ tamaño fijo,
  - ▶ tamaño variable;
5. Objetos o punteros, gestión de memoria;

# Lenguaje Fuente

Ingredientes que distinguen unos de otros

## Aspectos a considerar:

1. Estructuras de control;
2. Expresiones;
3. Tipos básicos;
4. Tipos estructurados:
  - ▶ tamaño fijo,
  - ▶ tamaño variable;
5. Objetos o punteros, gestión de memoria;
6. Funciones y parámetros; visibilidad (*scoping*);

# Lenguaje Fuente

Ingredientes que distinguen unos de otros

## Aspectos a considerar:

1. Estructuras de control;
2. Expresiones;
3. Tipos básicos;
4. Tipos estructurados:
  - ▶ tamaño fijo,
  - ▶ tamaño variable;
5. Objetos o punteros, gestión de memoria;
6. Funciones y parámetros; visibilidad (*scoping*);
7. Recursividad.

# Lenguaje Objeto

¿Por qué no directamente código nativo?

Hay varias fuentes de ineficiencia en el código generado:

1. Copiamos a un registro un valor que ya está en él;
2. copiamos a memoria un valor que ya está en esa posición;

# Lenguaje Objeto

¿Por qué no directamente código nativo?

Hay varias fuentes de ineficiencia en el código generado:

1. Copiamos a un registro un valor que ya está en él;
2. copiamos a memoria un valor que ya está en esa posición;
3. no aprovechamos bien la disponibilidad de varios registros;
4. no aprovechamos bien todo el repertorio de instrucciones máquina;

# Lenguaje Objeto

¿Por qué no directamente código nativo?

Hay varias fuentes de ineficiencia en el código generado:

1. Copiamos a un registro un valor que ya está en él;
2. copiamos a memoria un valor que ya está en esa posición;
3. no aprovechamos bien la disponibilidad de varios registros;
4. no aprovechamos bien todo el repertorio de instrucciones máquina;
5. es muy fácil que quede código “muerto” que en realidad nunca se puede ejecutar.

# Lenguaje Objeto

¿Por qué no directamente código nativo?

Hay varias fuentes de ineficiencia en el código generado:

1. Copiamos a un registro un valor que ya está en él;
2. copiamos a memoria un valor que ya está en esa posición;
3. no aprovechamos bien la disponibilidad de varios registros;
4. no aprovechamos bien todo el repertorio de instrucciones máquina;
5. es muy fácil que quede código “muerto” que en realidad nunca se puede ejecutar.

**Solución habitual:** dos, o a veces tres, lenguajes objeto.

1. generar un código intermedio y analizarlo de varias maneras para “optimizarlo”
2. y luego obtenemos código ejecutable nativo

# Lenguaje Objeto

¿Por qué no directamente código nativo?

Hay varias fuentes de ineficiencia en el código generado:

1. Copiamos a un registro un valor que ya está en él;
2. copiamos a memoria un valor que ya está en esa posición;
3. no aprovechamos bien la disponibilidad de varios registros;
4. no aprovechamos bien todo el repertorio de instrucciones máquina;
5. es muy fácil que quede código “muerto” que en realidad nunca se puede ejecutar.

**Solución habitual:** dos, o a veces tres, lenguajes objeto.

1. generar un código intermedio y analizarlo de varias maneras para “optimizarlo”
2. y luego obtenemos código ejecutable nativo
3. o bien un código interpretable por una máquina virtual.



# Desiderata

## Propiedades deseables:

- ▶ Próximo al lenguaje fuente (facilita el “front-end”).
- ▶ Próximo al lenguaje objeto (facilita el “back-end”).
- ▶ Permite implementar algoritmos sofisticados sobre fragmentos de código (facilita la “optimización” de código).

# Desiderata

## Propiedades deseables:

- ▶ Próximo al lenguaje fuente (facilita el “front-end”).
- ▶ Próximo al lenguaje objeto (facilita el “back-end”).
- ▶ Permite implementar algoritmos sofisticados sobre fragmentos de código (facilita la “optimización” de código).

Evidentemente, esos requisitos entran en conflicto mutuamente.

# Desiderata

## Propiedades deseables:

- ▶ Próximo al lenguaje fuente (facilita el “front-end”).
- ▶ Próximo al lenguaje objeto (facilita el “back-end”).
- ▶ Permite implementar algoritmos sofisticados sobre fragmentos de código (facilita la “optimización” de código).

Evidentemente, esos requisitos entran en conflicto mutuamente.

**Optimización** (nombre inadecuado): es especialmente importante porque el código generado suele tener ineficiencias obvias.

# Desiderata

## Propiedades deseables:

- ▶ Próximo al lenguaje fuente (facilita el “front-end”).
- ▶ Próximo al lenguaje objeto (facilita el “back-end”).
- ▶ Permite implementar algoritmos sofisticados sobre fragmentos de código (facilita la “optimización” de código).

Evidentemente, esos requisitos entran en conflicto mutuamente.

**Optimización** (nombre inadecuado): es especialmente importante porque el código generado suele tener ineficiencias obvias.

Hay que afrontar esa tarea con mucha precaución.

# Desiderata

## Propiedades deseables:

- ▶ Próximo al lenguaje fuente (facilita el “front-end”).
- ▶ Próximo al lenguaje objeto (facilita el “back-end”).
- ▶ Permite implementar algoritmos sofisticados sobre fragmentos de código (facilita la “optimización” de código).

Evidentemente, esos requisitos entran en conflicto mutuamente.

**Optimización** (nombre inadecuado): es especialmente importante porque el código generado suele tener ineficiencias obvias.

Hay que afrontar esa tarea con mucha precaución.

“Premature optimization is the root of all evil.”

(D.E. Knuth, C.A.R. Hoare)

# Códigos Intermedios

## Motivo del plural

Nada impide usar más de un código intermedio.

Cuando la distancia entre el código ejecutable y el fuente es más grande, puede ser conveniente usar dos.

- ▶ Facilitan el diseño del compilador.
- ▶ Cada tarea a realizar se puede elegir en qué fase se realiza.

# Códigos Intermedios

## Motivo del plural

Nada impide usar más de un código intermedio.

Cuando la distancia entre el código ejecutable y el fuente es más grande, puede ser conveniente usar dos.

- ▶ Facilitan el diseño del compilador.
- ▶ Cada tarea a realizar se puede elegir en qué fase se realiza.

(En particular, las tareas de optimización de código.)

# Códigos Intermedios

## Motivo del plural

Nada impide usar más de un código intermedio.

Cuando la distancia entre el código ejecutable y el fuente es más grande, puede ser conveniente usar dos.

- ▶ Facilitan el diseño del compilador.
- ▶ Cada tarea a realizar se puede elegir en qué fase se realiza.  
(En particular, las tareas de optimización de código.)
- ▶ Se puede decidir interpretar pero no compilar el último código intermedio



# Códigos Intermedios

## Motivo del plural

Nada impide usar más de un código intermedio.

Cuando la distancia entre el código ejecutable y el fuente es más grande, puede ser conveniente usar dos.

- ▶ Facilitan el diseño del compilador.
- ▶ Cada tarea a realizar se puede elegir en qué fase se realiza.  
(En particular, las tareas de optimización de código.)
- ▶ Se puede decidir interpretar pero no compilar el último código intermedio  
(o hacerlo sólo “just-in-time”).

¿Y cómo son?

1. Código de tres direcciones, con o sin llamadas a función.
2. Representación en árboles similares a los árboles sintácticos.

# Cuestiones Prácticas

¿Cómo lo combinamos con el análisis sintáctico y semántico?

La última fase de análisis dispone de una estructura de datos en la que se construye el código intermedio generado.

Puede ser:

- ▶ Una **estructura arborescente** (*abstract syntax tree*), similar al árbol de **análisis sintáctico** pero reducido a la información imprescindible.
- ▶ Una estructura arborescente pero más alejada de la sintaxis, **orientada al código** a generar.
- ▶ Una **estructura secuencial** en memoria, lo cual nos permite varios recorridos (por ejemplo para colocar etiquetas de salto coherentes);
- ▶ Directamente el **fichero de salida**, en el que vamos escribiendo el resultado del paso correspondiente;

Depende de cuánto de lejos estén el lenguaje fuente y el objeto.

# Código de Tres Direcciones

Uno concreto y sencillísimo para nuestros primeros ejemplos y ejercicios

Vamos a simplificar un poco el código de tres direcciones.

```
# comentario
$p2 :read           # lectura
$p2 :write          # escritura
$p4 : $p3           # copia
$p21 : $p32 + $p13 # operacion, admite +, -, *, /
ident:              # etiqueta
$p8 : jump ident    # salto condicional: salta si <= 0
```

## Simplificaciones:

Todas las variables son “temporales” ( se ordena leer y escribir en memoria sin decir donde) y **equivalentes** entre sí(todos son números enteros).

(No distinguimos acumulador, ni registros entre sí, ni registros de posiciones de memoria; no hay *offsets*...)

# Un Ejemplo Sencillo

El de siempre, claro

```
### 3-address code

                                # "el factorial"
                                # dato
$p2 : read
                                # inicializa a uno
$p3 : 1
                                # bucle
loop0:
                                # salir si dato cero o negativo
$p2 : jump end0
                                # multiplica
$p3 : $p3 * $p2
                                # reduce
$p2 : $p2 - $p1
                                # escribe resultado parcial
$p3 : write
                                # comprueba condicion del bucle
$p0 : jump loop0
                                # fin de bucle y programa
end0:

### End of 3-address code
```

# Modus Operandi

¿Cómo se logra construir cosas así?

Ejemplo:

La rutina semántica correspondiente a multiplicar expresiones.

`emit()`: función que “emite” una nueva instrucción de tres direcciones y la añade al código que estamos generando.

Valor semántico de `expr`: posición de la variable que contiene el resultado.

```
expr : expr POR expr
    {
    tempvarnum = newtempvar();
    emit("$p",tempvarnum," : $p",$1," * p",$3," # mult.\n")
    $$ = tempvarnum;
    }
```

## Traducción de una Expresión

La traducción es una función que toma una Expresión, la tabla de símbolos, la tabla de funciones y un registro. Se denota por  $TransExp(Exp, vtable, ftable, place)$  devuelve Code

num	v= value(num) place=v
id	x=lookup(vtable,name(id)) place=x
unop Exp1	code=TransExp(Exp1,vtable,ftable,\$p0) code+\$pe= unop \$p0+place=\$pe
Exp1 binop Exp2	code1=TransExp(Exp1,vtable,ftable,\$p0) code2=TransExp(Exp2,vtable,ftable,\$p1) code1+code2+\$pe=\$p0 binop \$p1+place=\$pe

Cuadro: Tabla de Traducción

## Tabla de Traducción

Ahora traducimos conjuntos de Expresiones,  
*TransExps(Exp,vtable,ftable)* devuelve Code

Exp	code=TransExp(Exp,vtable,ftable,p0)
Exps Exp	code=TransExp(Exp,vtable,ftable,p0) code1=TransExps(Exps,vtable,ftable) code+code1

Cuadro: Tabla de Traducción

# Generación de Código Intermedio

A partir de aquí, ir siguiendo

Planteamos sucesivamente:

- ▶ generación de código para cada forma de las **expresiones** (gestión de variables temporales),
- ▶ generación de código para el repertorio de **instrucciones** de alto nivel (gestión de las etiquetas),
- ▶ generación de código para **tipos estructurados** (gestión de zonas de memoria),
- ▶ generación de código que use el *heap* con **punteros**,
- ▶ generación de código para **llamadas a función** (gestión de parámetros y resultados, gestión de ámbitos de visibilidad, **recursividad**...)
- ▶ ...

En cuanto tengamos los diagramas en T, haremos algunas de estas cosas para nuestro código simplificado y para MIPS.