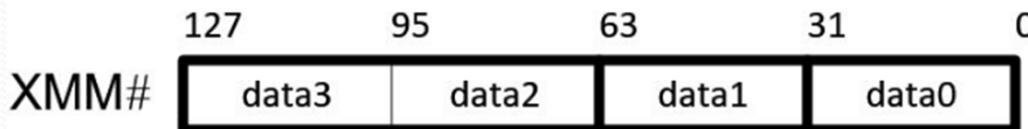


Subword Parallelism

Subword parallelism

- **Subword parallelism.** Capacidad de las CPUs modernas de operar sobre datos empacados en un registro.
- También se le conoce como SWAR (SIMD within a register).
- Ejemplo en x86:
- En 1999, la extensión SSE (Streaming SIMD Extensions) agregó 70 instrucciones y 8 registros, xmm0 a xmm7, de 128 bits.
- Luego se agregaron otros 8 registros, xmm8 a xmm15.
- Cada registro puede guardar empacados 16 bytes, 8 palabras (words), 4 palabras dobles (double words), 2 palabras cuádruples (quad words).

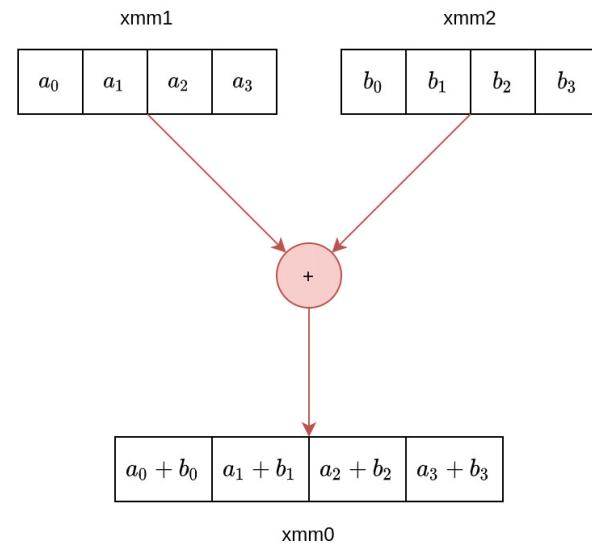
Subword parallelism



Fuente: <https://www.songho.ca/misc/sse/sse.html>

- Hay instrucciones para operar sobre los datos de manera *independiente* y en *paralelo*.
- La instrucción vaddps xmm0, xmm1, xmm2 interpreta como float las 4 palabras dobles empacadas en xmm1 y xmm2, las suma en paralelo y las guarda en xmm0.

Subword parallelism



Fuente: https://www.researchgate.net/figure/Figure-S12-The-two-fundamental-SIMD-instructions-for-the-prefix-sum-Left-vaddps_fig5_355221823

Extensiones SIMD en x86

- 64 bits. MMX (1997).
- 128 bits. Streaming SIMD Extensions: SSE (1999), SSE2 (2000), SSE3 (2004), SSSE3 (2006), SSE4.1 (2008), SSE4.2 (2008).
- 256 bits. Advanced Vector Extensions: AVX (2011), AVX2 (2013).
- 512 bits. AVX-512 (2017).

Ejemplo 1

- En graficación por computadora, la suma de vectores es muy utilizada.
- Para sumar dos vectores de cuatro componentes de precisión simple usando x86 se requieren cuatro instrucciones de suma de punto flotante.

$$v3.x = v1.x + v2.x;$$

$$v3.y = v1.y + v2.y;$$

$$v3.z = v1.z + v2.z;$$

$$v3.w = v1.w + v2.w;$$

- Esto corresponde a cuatro instrucciones fadd en x86.

Ejemplo 1

- Con SSE, una instrucción de suma empacada de 128 bits sustituye a las cuatro sumas.

movaps xmm0, [v1] ; **xmm0 = v1.w | v1.z | v1.y | v1.x**

addps xmm0, [v2] ; **xmm0 = v1.w+v2.w | v1.z+v2.z | v1.y+v2.y | v1.x+v2.x**

movaps [v3], xmm0 ; **v3[x|y|z|w] = xmm0**

Ejemplo 2

- Usando instrucciones SIMD programar una función en ensamblador que sume dos vectores de tipo float.

Función en C

```
void add(float *z, float *x, float *y, int n)
{
    int i;
    for (i = 0; i < n; i++) {
        z[i] = x[i] + y[i];
    }
}
```

Programa principal en C

```
int main()
{
    float x[] = {1, 2, 3, 4, 5};
    float y[] = {11, 12, 13, 14, 15};
    float z[5];
    int i, n = 5;
    add (&z[0], &x[0], &y[0], n);
    for (i = 0; i < n; i++) {
        printf("%f\n", z[i]);
    }
    return 0;
}
```

Función en ensamblador

```
; rcx points to z; rdx points to x; r8 points to y; r9 has n  
NSE    equ 8  
        xor rax, rax  
Loop1: mov r10, r9  
        sub r10, rax  
        cmp r10, NSE  
        jb Loop2  
                ; num_simd_elements  
                ; i = 0  
                ; r10 = n  
                ; r10 = n - i  
                ; is n - i < NSE?  
                ; jump if yes
```

Función en ensamblador

; Calculate $z[i:i+7] = x[i:i+7] + y[i:i+7]$

```
vmovups ymm0,ymmword ptr [rdx+rax*4] ; ymm0 = x[i:i+7]
vmovups ymm1,ymmword ptr [r8+rax*4]   ; ymm1 = y[i:i+7]
vaddps ymm2,ymm0,ymm1                 ; z[i:i+7] = x[i:i+7] + y[i:i+7]
vmovups ymmword ptr [rcx+rax*4],ymm2 ; save z[i:i+7]
```

add rax,NSE ; i += NSE

jmp Loop1 ; repeat Loop1 until done

Funciones en ensamblador

```
Loop2: cmp rax, r9          ; is i >= n?  
       jae Done             ; jump if yes  
;Calculate z[i] = x[i] + y[i] for remaining elements  
       vmovss xmm0,real4 ptr [rdx+rax*4]    ; xmm0 = x[i]  
       vmovss xmm1,real4 ptr [r8+rax*4]     ; xmm1 = y[i]  
       vaddss xmm2,xmm0,xmm1            ; z[i] = x[i] + y[i]  
       vmovss real4 ptr [rcx+rax*4],xmm2   ; save z[i]  
       inc rax                  ; i += 1  
       jmp Loop2               ; repeat Loop2 until done  
Done:  vzeroupper           ; clear upper bits of ymm regs  
       ret                     ; return to caller
```

Funciones intrínsecas

- Usando funciones intrínsecas se puede obtener el mismo resultado utilizando C o C++.
- **Función intrínseca.** Función que se puede llamar desde C/C++ y que el compilador la va a sustituir por una instrucción SIMD en ensamblador.
- Ejemplo: la función `_mm256_add_ps()` se sustituye por `vaddss` para sumar 8 elementos float empacados en un registro.

Requisitos

- Contar con una CPU con extensiones SIMD.
- Contar con un compilador que reconozca funciones intrínsecas: Visual Studio, gcc, Intel C++ Compiler.

Suma de vectores con intrínsecas

```
void CalcZ_Iavx(float* z, const float* x, const float* y, size_t n)
{
    size_t i = 0;
    const size_t num_simd_elements = 8;
    for (; n - i >= num_simd_elements; i += num_simd_elements) {
        // Calculate z[i:i+7] = x[i:i+7] + y[i:i+7]
        __m256 x_vals = _mm256_loadu_ps(&x[i]);
        __m256 y_vals = _mm256_loadu_ps(&y[i]);
        __m256 z_vals = _mm256_add_ps(x_vals, y_vals);
        _mm256_storeu_ps(&z[i], z_vals);
    }
}
```

Suma de vectores con intrínsecas

// Calculate $z[i] = x[i] + y[i]$ for any remaining elements

```
for (; i < n; i += 1)
```

```
    z[i] = x[i] + y[i];
```

```
}
```

Bibliografía

- Modern Parallel Programming with C++ and Assembly Language: X86 SIMD Development Using AVX, AVX2, and AVX-512, 1st Edition
- Daniel Kusswurm
- Apress, 2022
- ISBN-10: 1484279174
- ISBN-13: 978-1484279175

Recursos

- Intel Intrinsics Guide
- <https://www.intel.com/content/www/us/en/docs/intrinsics-guide/index.html>
- Intel 64 and IA-32 Architectures Software Developer's Manuals
- <https://www.intel.com/content/www/us/en/developer/articles/technical/intel-sdm.html>