Introduzione alla Programmazione Parallela

Ultimo aggiornamento: 6 gennaio 2016

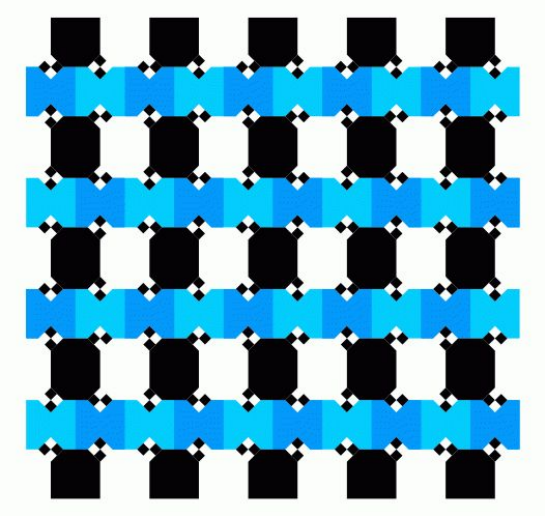

Camil Demetrescu
Dipartimento di Ingegneria Informatica, Automatica e Gestionale "A. Ruberti"
Sapienza Università di Roma

Indice

2 Vettorizzazione

La **vettorizzazione** è una classica forma di parallelismo SIMD a livello di istruzione. Consente di effettuare operazioni supportate nativamente dall'hardware su piccoli vettori di numeri. Ad esempio, con una singola istruzione macchina è possibile sommare due vettori di 32 char, 16 short, o 8 int. La vettorizzazione può essere effettuata **manualmente dal programmatore**, ma **spesso sono i compilatori a farlo in automatico**, generando codice assembly che usa istruzioni vettoriali. Ad esempio, molte funzioni della libreria C, come quelle di manipolazione delle stringhe, sono compilate in forma vettorizzata.

Le CPU moderne sono equipaggiate con **estensioni** che forniscono un ampio set di **registri e istruzioni macchina vettoriali**, originariamente introdotti per supportare lo sviluppo di applicazioni multimediali. In particolare, le architetture x86 hanno una lunga storia di estensioni successive, ognuna delle quali estende le precedenti con nuove funzionalità: MMX (1996), 3DNow! (1998), SSE (1999), SSE2 (2001), SSE3 (2004), SSSE3 (2006), SSE4 (2006), AVX (2008), AVX2 (2012), AXV-512 (2015).

Per svincolare il programmatore dal dover sviluppare direttamente in assembly le applicazioni che usano estensioni vettoriali, i compilatori forniscono una batteria di **intrinsic**, cioè particolari costrutti di alto livello (come tipi e funzioni C) che vengono tradotti direttamente in termini di costrutti dell'instruction set architecture (ISA) della macchina soggiacente.

Esempio 1. Per sommare due vettori `a` e `b` di 4 `int` usando intrinsic SSE2 basta semplicemente scrivere `c = _mm_add_epi32(a,b)`, dove `a`, `b` e `c` sono variabili del tipo vettoriale `__m128i`. La chiamata `_mm_add_epi32` viene tradotta nell'istruzione macchina `paddd`. L'esempio seguente mostra come leggere, scrivere ed effettuare operazioni su variabili vettoriali:

```
#include <immintrin.h>
#include <stdio.h>

void somma(int A[4], int B[4], int C[4]) {
    __m128i a, b, c;                        // dich. variabili vettoriali
    a = _mm_load_si128((const __m128i*)A); // copia primo vettore in a
    b = _mm_load_si128((const __m128i*)B); // copia secondo vettore in b
    c = _mm_add_epi32(a,b);                // calcola la somma vett. di a e b
    _mm_store_si128((__m128i*)C, c);       // copia risultato c in C
}

int main() {
    int A[4] = { 1, 2, 3, 4 };
    int B[4] = { 4, 3, 2, 1 };
    int C[4];
```

```
    somma(A,B,C);
    printf("%d %d %d %d\n", C[0], C[1], C[2], C[3]);   // stampa 5 5 5 5
    return 0;
}
```

Si noti l'uso degli intrinsic load e store per trasferire dati da memoria a variabile vettoriale e viceversa. Vedremo le istruzioni più in dettaglio nel seguito. In questa dispensa analizzeremo gli intrinsic più frequentemente usati, per una trattazione più completa si rimanda al sito Web [IntelIntr], che fornisce una documentazione dettagliata degli intrinsic della famiglia x86.

2.1 Compilazione di programmi che usano estensioni vettoriali

In questa dispensa assumiamo di usare una piattaforma equipaggiata con compilatore `gcc`. Per compilare un programma che usa estensioni vettoriali, includeremo la header `immintrin.h` che rende visibili gli intrinsic e aggiungeremo alla riga di comando `gcc` un'opzione per abilitare il supporto alla vettorizzazione. Se `X` è il nome dell'estensione da usare, l'opzione da usare è `-mX`. Ad esempio, per usare AVX2 scriveremo `-mavx2`. Si noti che ogni opzione include tutte quelle precedenti. Ad esempio, usando `-msse2` si possono usare tutte le funzionalità offerte da SSE e SSE2.

Esempio 2. Il programma dell'esempio 1 può essere compilato con `gcc -msse2 vecsum.c -O2 -o vecsum` ed eseguito con `./vecsum`.

Compilando il programma con `gcc -msse2 vecsum.c -O2 -S`, si ottiene il seguente codice x86-64 per la funzione `somma`[1]:

```
somma:
      movdqa (%rdi), %xmm0    # <-- _mm_load_si128
      paddd (%rsi), %xmm0     # <-- _mm_add_epi32
      movdqa %xmm0, (%rdx)    # <-- _mm_store_si128
      ret
```

Si noti come gli intrinsic si mappino su istruzioni macchina e registri (`xmm0` nell'esempio).

2.2 Tipi vettoriali

I **tipi vettoriali** descrivono oggetti vettoriali che possono essere tenuti in particolari registri della CPU. I tipi vettoriali vengono anche chiamati **packed data type**, poiché consentono di impaccare più valori scalari dello stesso tipo in un unico oggetto. I tipi principali sono:

[1] Si noti che, secondo le convenzioni AMD64 ABI, i primi tre parametri della funzione `somma` (indirizzi degli array A, B, C) sono passati nei registri `rdi`, `rsi` e `rdx`, rispettivamente.

Tipo			Dimensione	Registri usati	Estensione vettoriale x86
Intero	Precisione singola	Precisione doppia			
`__m64`			8 byte	8 `(MM0-MM7)`	MMX
`__m128i`	`__m128`	`__m128d`	16 byte	16 `(XMM0-XMM15)`	SSE
`__m256i`	`__m256`	`__m256d`	32 byte	16 `(YMM0-YMM15)`	AVX
`__m512i`	`__m512`	`__m512d`	64 byte	32 `(ZMM0-ZMM31)`	AVX-512

La loro capienza in termini vettoriali è come segue:

Intero	Capienza			Precis. singola	Capienza	Precis. doppia	Capienza
`__m64`	`char[8]`	`short[4]`	`int[2]`				
`__m128i`	`char[16]`	`short[8]`	`int[4]`	**`__m128`**	`float[4]`	**`__m128d`**	`double[2]`
`__m256i`	`char[32]`	`short[16]`	`int[8]`	**`__m256`**	`float[8]`	**`__m256d`**	`double[4]`
`__m512i`	`char[64]`	`short[32]`	`int[16]`	**`__m512`**	`float[16]`	**`__m512d`**	`double[8]`

Si noti che i tipi a 512 bit non sono ancora supportati, ma è previsto il loro inserimento nell'architettura Knights Landing di Intel nel 2016. Tecnicamente, i tipi vettoriali sono `struct` C. E' quindi possibile assegnare un oggetto vettoriale ad un altro mediante l'operatore di assegnamento `=`.

Esempio.

```
__m128i a = ...;
__m128i b = a;    // ok, è possibile assegnare un oggetto vett. a un
altro
```

Inoltre, passare un oggetto vettoriale come **parametro a una funzione** implica passare una copia dell'intero oggetto, e non del solo indirizzo come avverrebbe passando un array come parametro.

2.3 Istruzioni per leggere e scrivere su oggetti vettoriali

Per poter effettuare un calcolo vettoriare è innanzitutto necessario caricare l'input in opportuni oggetti vettoriali. Allo stesso modo, è necessario poter estrarre il risultato dagli oggetti vettoriali che sono il risultato del calcolo.

2.3.1 Allineamento in memoria

Le estensioni vettoriali forniscono istruzioni che permettono di trasferire dati da memoria a oggetto vettoriale, e viceversa. Ci sono **due versioni** di queste istruzioni: quelle che richiedono che l'indirizzo di memoria acceduto sia **allineato** a un multiplo della dimensione dell'oggetto vettoriale copiato, e quelle che possono accedere a **qualsiasi indirizzo anche non allineato**. Le versioni allineate garantiscono prestazioni migliori. Se si passa un indirizzo non allineato a una funzione che richiede allineamento, potrebbe generarsi un errore di accesso alla memoria durante l'esecuzione (**segmentation fault**, o general-protection exception).

Allineamento di variabili.
Il compilatore `gcc` fornisce supporto per dichiarare variabili allineate a indirizzi multipli di una costante `n` usando la direttiva `__attribute__((aligned(n)))`.

Esempio. La seguente dichiarazione introduce un array di interi allineato a 16 byte:

```
int v[4] __attribute__((aligned(16))) = { 3, 5, 7, 1 };
```

Allineamento di blocchi allocati dinamicamente.
La funzione `malloc` potrebbe non garantire il corretto allineamento di oggetti vettoriali come quelli a 256 bit. Per allocare dinamicamente blocchi con l'allineamento desiderato è possibile usare la funzione `posix_memalign` definita dallo standard POSIX 1003.1d [PosixMemalign], oppure funzioni come `memalign` o `valloc` fornite dalla GNU standard library (che potrebbero non essere tuttavia disponibili su tutte le piattaforme) [GNUMemalign].

2.3.2 Copia da memoria a vettore (load)

Queste operazioni consentono di copiare dati da memoria a oggetto vettoriale.

`__m128i` **`_mm_load_si128`** `(__m128i const* mem_addr)` `__m128i` **`_mm_loadu_si128`**`(__m128i const* mem_addr)`			array interi all. → `__m128i` array interi → `__m128i`
Opzione gcc	`-msse2`	**Istruzione**	`movdqa xmm, m128` `movdqu xmm, m128`
Descrizione	Restituisce oggetto `__m128i` inizializzato con i 16 byte di dati **interi** (array di `char`, `short`, `int`, `long`, con o senza segno) presi dall'indirizzo di memoria `mem_addr`. La versione `_mm_load_si128` richiede che `mem_addr` sia **allineato** a un multiplo di 16 byte.		

Esempio	`int va[4] __attribute__((aligned(16))) = { 3, 5, 7, 1 };`
	`__m128i a = _mm_load_si128((__m128i const*)va);`
	
	`int vu[4] = { 3, 5, 7, 1 };`
	`__m128i b = _mm_loadu_si128((__m128i const*)vu);`		

`__m256i` **`_mm256_load_si256`** `(__m256i const* mem_addr)` `__m256i` **`_mm256_loadu_si256`**`(__m256i const* mem_addr)`			array interi all. → `__m256i` array interi → `__m256i`
Opzione gcc	`-mavx`	**Istruzione**	`vmovdqa ymm, m256` `vmovdqu ymm, m256`
Descrizione	Restituisce oggetto `__m256i` inizializzato con i 32 byte di dati **interi** (array di `char`, `short`, `int`, `long`, con o senza segno) presi dall'indirizzo di memoria `mem_addr`. La versione `_mm256_load_si256` richiede che `mem_addr` sia **allineato** a un multiplo di 32 byte.		

Esempio	`int va[8] __attribute__((aligned(32))) = { 3, 5, 7, 1, 3, 2, 6, 1 };`
	`__m256i a = _mm256_load_si256((__m256i const*)va);`
	
	`int vu[8] = { 3, 5, 7, 1, 3, 2, 6, 1 };`
	`__m256i b = _mm256_loadu_si256((__m256i const*)vu);`		

Si noti che le stesse istruzioni possono essere usate per trasferire array di tipi interi diversi. Per questo motivo, è richiesto un cast dell'indirizzo (es. `(__m256i const*)v`).

`__m128` **`_mm_load_ps`** `(float const* mem_addr)` `__m128` **`_mm_loadu_ps`**`(float const* mem_addr)`			`float[4]` all. → `__m128` `float[4]` → `__m128`
Opzione gcc	`-msse`	**Istruzione**	`movaps xmm, m128` `movups xmm, m128`
Descrizione	Restituisce oggetto `__m128` inizializzato con l'array di 4 `float` all'indirizzo di memoria `mem_addr`. La versione `_mm_load_ps` richiede che `mem_addr` sia **allineato** a un multiplo di 16 byte.		

Esempio	`float va[4] __attribute__((aligned(16))) = { 3.1, 5.3, 7.9, 1 };`
	`__m128 a = _mm_load_ps(va);`
	
	`float vu[4] = { 3.1, 5.3, 7.9, 1 };`
	`__m128 b = _mm_loadu_ps(vu);`		

`__m128d` **`_mm_load_pd`** `(double const* mem_addr)` `__m128d` **`_mm_loadu_pd`**`(double const* mem_addr)`			`double[2]` all. → `__m128d` `double[2]` → `__m128d`
Opzione gcc	`-msse2`	**Istruzione**	`movapd xmm, m128` `movupd xmm, m128`
Descrizione	Restituisce oggetto `__m128d` inizializzato con l'array di 2 `double` all'indirizzo di memoria `mem_addr`. La versione `_mm_load_pd` richiede che `mem_addr` sia **allineato** a un multiplo di 16 byte.		

Esempio	`double va[2] __attribute__((aligned(16))) = { 3.1, 5.3 };`
	`__m128d a = _mm_load_pd(va);`
	
	`double vu[2] = { 3.1, 5.3 };`		

	`__m128d b = _mm_loadu_pd(vu);`

`__m256 _mm256_load_ps (float const* mem_addr)` `__m256 _mm256_loadu_ps(float const* mem_addr)`			`float[8]` all. → `__m256` `float[8]` → `__m256`
Opzione gcc	`-mavx`	**Istruzione**	`vmovaps ymm, m256` `vmovups ymm, m256`
Descrizione	Restituisce oggetto `__m256` inizializzato con l'array di 8 `float` all'indirizzo di memoria `mem_addr`. La versione `_mm256_load_ps` richiede che `mem_addr` sia **allineato** a un multiplo di 32 byte.		

Esempio	`float va[8] __attribute__((aligned(32))) =`
	`  { 3.1, 5.3, 7.9, 1, 3.1, 5.3, 7.9, 1 };`
	`__m256 a = _mm256_load_ps(va);`
	
	`float vu[8] = { 3.1, 5.3, 7.9, 1, 3.1, 5.3, 7.9, 1 };`
	`__m256 b = _mm256_loadu_ps(vu);`		

`__m256d _mm256_load_pd (double const* mem_addr)` `__m256d _mm256_loadu_pd(double const* mem_addr)`			`double[4]` all. → `__m256d` `double[4]` → `__m256d`
Opzione gcc	`-mavx`	**Istruzione**	`vmovapd ymm, m256` `vmovupd ymm, m256`
Descrizione	Restituisce oggetto `__m256d` inizializzato con l'array di 4 `double` all'indirizzo di memoria `mem_addr`. La versione `_mm256_load_pd` richiede che `mem_addr` sia **allineato** a un multiplo di 32 byte.		

Esempio	`double va[4] __attribute__((aligned(32))) = { 3.1, 5.3, 7.9, 1 };`
	`__m256d a = _mm256_load_pd(va);`
	
	`double vu[4] = { 3.1, 5.3, 7.9, 1 };`
	`__m256d b = _mm256_loadu_pd(vu);`		

2.3.3 Copia da vettore a memoria (store)

Queste operazioni consentono di copiare dati da un oggetto vettoriale a memoria. Come per la load, ci sono due versioni, a seconda che l'indirizzo destinazione sia allineato o meno.

`void _mm_store_si128 (__m128i* mem_addr, __m128i a)` `void _mm_storeu_si128(__m128i* mem_addr, __m128i a)`			`__m128i` → array interi all. `__m128i` → array interi
Opzione gcc	`-msse2`	**Istruzione**	`movdqa m128, xmm` `movdqu m128, xmm`
Descrizione	Copia l'oggetto `a` nei 16 byte di dati **interi** (array di `char`, `short`, `int`, `long`, con o senza		

	segno) all'indirizzo di memoria `mem_addr`. La versione `_mm_store_si128` richiede che `mem_addr` sia **allineato** a un multiplo di 16 byte.

Esempio	`__m128i a = _mm_set_epi32(2, 5, 3, 1);`
	`int va[4] __attribute__((aligned(16)));`
	`_mm_store_si128((__m128i*)va, a);`
	
	`__m128i b = _mm_set_epi32(2, 5, 3, 1);`
	`int vu[4];`
	`_mm_storeu_si128((__m128i*)vu, b);`

`void` **`_mm256_store_si256`** `(__m256i* mem_addr, __m256i a)` `void` **`_mm256_storeu_si256`**`(__m256i* mem_addr, __m256i a)`			`__m256i` → array interi all. `__m256i` → array interi
Opzione gcc	`-msse2`	**Istruzione**	`vmovdqa m256, ymm` `vmovdqu m256, ymm`
Descrizione	Copia l'oggetto `a` nei 32 byte di dati **interi** (array di `char`, `short`, `int`, `long`, con o senza segno) all'indirizzo di memoria `mem_addr`. La versione `_mm_store_si128` richiede che `mem_addr` sia **allineato** a un multiplo di 32 byte.		

Esempio	`__m256i a = _mm256_set_epi32(2, 5, 3, 1, 7, 9, 4, 6);`
	`int va[8] __attribute__((aligned(32)));`
	`_mm256_store_si256((__m256i*)va, a);`
	
	`__m256i b = _mm256_set_epi32(2, 5, 3, 1, 7, 9, 4, 6);`
	`int vu[8];`
	`_mm256_storeu_si256((__m256i*)vu, b);`		

`void` **`_mm_store_ps`** `(float* mem_addr, __m128 a)` `void` **`_mm_storeu_ps`**`(float* mem_addr, __m128 a)`			`__m128` → `float[4]` all. `__m128` → `float[4]`
Opzione gcc	`-msse`	**Istruzione**	`movaps m128, xmm` `movups m128, xmm`
Descrizione	Copia l'oggetto `a` nell'array di 4 `float` all'indirizzo di memoria `mem_addr`. La versione `_mm_store_ps` richiede che `mem_addr` sia **allineato** a un multiplo di 16 byte.		

Esempio	`__m128 a = _mm_set_ps(2.1, 5.2, 3.1, 1.9);`
	`float va[4] __attribute__((aligned(16)));`
	`_mm_store_ps(va, a);`
	
	`__m128 b = _mm_set_ps(2.1, 5.2, 3.1, 1.9);`
	`float vu[4];`
	`_mm_storeu_ps(vu, b);`		

`void` **`_mm256_store_ps`** `(float* mem_addr, __m256 a)` `void` **`_mm256_storeu_ps`**`(float* mem_addr, __m256 a)`			`__m256` → `float[8]` all. `__m256` → `float[8]`
Opzione gcc	`-mavx`	**Istruzione**	`vmovaps m256, ymm` `vmovups m256, ymm`
Descrizione	Copia l'oggetto `a` nell'array di 8 `float` all'indirizzo di memoria `mem_addr`. La versione `_mm256_store_ps` richiede che `mem_addr` sia **allineato** a un multiplo di 32 byte.		

Esempio	`__m256 a = _mm256_set_ps(2.1, 5.2, 3.1, 1.9, 7.3, 9.5, 4.3, 6.7);`
	`float va[8] __attribute__((aligned(32)));`
	`_mm256_store_ps(va, a);`
	
	`__m256 b = _mm256_set_ps(2.1, 5.2, 3.1, 1.9, 7.3, 9.5, 4.3, 6.7);`
	`float vu[8];`
	`_mm256_storeu_ps(vu, b);`		

`void` **`_mm_store_pd`** `(double* mem_addr, __m128d a)` `void` **`_mm_storeu_pd`**`(double* mem_addr, __m128d a)`			`__m128d` → `double[2]` all. `__m128d` → `double[2]`
Opzione gcc	`-msse2`	**Istruzione**	`movapd m128, xmm` `movupd m128, xmm`
Descrizione	Copia l'oggetto `a` nell'array di 2 `double` all'indirizzo di memoria `mem_addr`. La versione `_mm_store_pd` richiede che `mem_addr` sia **allineato** a un multiplo di 16 byte.		

Esempio	`__m128d a = _mm_set_pd(2.1, 5.2);`
	`double va[2] __attribute__((aligned(16)));`
	`_mm_store_pd(va, a);`
	
	`__m128d b = _mm_set_pd(2.1, 5.2);`
	`double vu[2];`
	`_mm_storeu_pd(vu, b);`		

`void` **`_mm256_store_pd`** `(double* mem_addr, __m256d a)` `void` **`_mm256_storeu_pd`**`(double* mem_addr, __m256d a)`			`__m256d` → `double[4]` all. `__m256d` → `double[4]`
Opzione gcc	`-mavx`	**Istruzione**	`vmovapd m256, ymm` `vmovupd m256, ymm`
Descrizione	Copia l'oggetto `a` nell'array di 4 `double` all'indirizzo di memoria `mem_addr`. La versione `_mm256_store_ps` richiede che `mem_addr` sia **allineato** a un multiplo di 32 byte.		

Esempio	`__m256d a = _mm256_set_pd(2.1, 5.2, 3.1, 1.9);`
	`double va[4] __attribute__((aligned(32)));`
	`_mm256_store_pd(va, a);`
	
	`__m256d b = _mm256_set_pd(2.1, 5.2, 3.1, 1.9);`		

	`double vu[4];` `_mm256_storeu_pd(vu, b);`

2.4 Operazioni aritmetiche

2.4.1 Addizione e sottrazione

Le operazioni di **sottrazione** sono del tutto analoghe alle seguenti, rimpiazzando `add` con `sub`.

`__m128i` **`_mm_add_epi8`** `(__m128i a, __m128i b)`
`__m128i` **`_mm_add_epi16`**`(__m128i a, __m128i b)`
`__m128i` **`_mm_add_epi32`**`(__m128i a, __m128i b)`
`__m128i` **`_mm_add_epi64`**`(__m128i a, __m128i b)`
			`__m128i + __m128i`

Opzione gcc	`-msse2`	**Istruzione**	`paddb xmm, xmm`
			`paddw xmm, xmm`
			`paddd xmm, xmm`
			`paddq xmm, xmm`

Descrizione	Calcola `a+b` come vettori di `char` (`epi8`), `short` (`epi16`), `int` (`epi32`), oppure `long` (`epi64`) e restituisce il risultato.		

Esempio	`__m128i a = _mm_set_epi32(4, 3, 2, 1);`
	`__m128i b = _mm_set_epi32(1, 2, 3, 4);`
	`__m128i c = _mm_add_epi32(a,b);  // c = [5, 5, 5, 5]`		

`__m256i` **`_mm256_add_epi8`** `(__m256i a, __m256i b)`
`__m256i` **`_mm256_add_epi16`**`(__m256i a, __m256i b)`
`__m256i` **`_mm256_add_epi32`**`(__m256i a, __m256i b)`
`__m256i` **`_mm256_add_epi64`**`(__m256i a, __m256i b)`
			`__m256i + __m256i`

Opzione gcc	`-mavx2`	**Istruzione**	`vpaddb ymm, ymm, ymm`
			`vpaddw ymm, ymm, ymm`
			`vpaddd ymm, ymm, ymm`
			`vpaddq ymm, ymm, ymm`

Descrizione	Calcola `a+b` come vettori di `char` (`epi8`), `short` (`epi16`), `int` (`epi32`), oppure `long` (`epi64`) e restituisce il risultato.		

Esempio	`__m256i a = _mm256_set_epi32(1, 2, 3, 4, 5, 6, 7, 8);`
	`__m256i b = _mm256_set_epi32(8, 7, 6, 5, 4, 3, 2, 1);`
	`__m256i c = _mm256_add_epi32(a,b);  // c = [5, 5, 5, 5, 5, 5, 5, 5]`		

`__m128` **`_mm_add_ps`**`(__m128 a, __m128 b)`			`__m128 + __m128`
Opzione gcc	`-msse`	**Istruzione**	`addps xmm, xmm`
Descrizione	Calcola `a+b` come vettori di `float` e restituisce il risultato.		

Esempio	`__m128 a = _mm_set_ps(4.0, 3.0, 2.0, 1.0);`
	`__m128 b = _mm_set_ps(1.0, 2.0, 3.0, 4.0);`
	`__m128 c = _mm_add_ps(a,b);  // c = [5.0, 5.0, 5.0, 5.0]`

`__m128d` **`_mm_add_pd`**`(__m128d a, __m128d b)`			`__m128d + __m128d`
Opzione gcc	`-msse2`	**Istruzione**	`addpd xmm, xmm`
Descrizione	Calcola `a+b` come vettori di `double` e restituisce il risultato.		

Esempio	`__m128d a = _mm_set_pd(4.0, 3.0);`
	`__m128d b = _mm_set_pd(1.0, 2.0);`
	`__m128d c = _mm_add_pd(a,b);  // c = [5.0, 5.0]`		

`__m256` **`_mm256_add_ps`**`(__m256 a, __m256 b)`			`__m256 + __m256`
Opzione gcc	`-mavx`	**Istruzione**	`vaddps ymm, ymm, ymm`
Descrizione	Calcola `a+b` come vettori di `float` e restituisce il risultato.		

Esempio	`__m256 a = _mm256_set_ps(4.0, 3.0, 2.0, 1.0, 4.0, 3.0, 2.0, 1.0);`
	`__m256 b = _mm256_set_ps(1.0, 2.0, 3.0, 4.0, 1.0, 2.0, 3.0, 4.0);`
	`__m256 c = _mm256_add_ps(a,b);  // c = [5.0, 5.0, 5.0, 5.0, ...]`		

`__m256d` **`_mm256_add_pd`**`(__m256d a, __m256d b)`			`__m256d + __m256d`
Opzione gcc	`-mavx`	**Istruzione**	`vaddpd ymm, ymm, ymm`
Descrizione	Calcola `a+b` come vettori di `double` e restituisce il risultato.		

Esempio	`__m256d a = _mm256_set_pd(4.0, 3.0, 2.0, 1.0);`
	`__m256d b = _mm256_set_pd(1.0, 2.0, 3.0, 4.0);`
	`__m256d c = _mm256_add_pd(a,b);  // c = [5.0, 5.0, 5.0, 5.0]`		

2.4.2 Moltiplicazione

`__m128i` **`_mm_mullo_epi16`**`(__m128i a, __m128i b)` `__m128i` **`_mm_mullo_epi32`**`(__m128i a, __m128i b)`			`__m128i * __m128i`
Opzione gcc	`-msse2` (`epi16`) `-msse4.1` (`epi32`)	**Istruzione**	`pmullw xmm, xmm` `pmulld xmm, xmm`
Descrizione	Moltiplica gli elementi corrispondenti in `a` e `b` come vettori di `short` (`epi16`) o `int` (`epi32`) e restituisce il risultato. Ciascun prodotto di valori a n bit è calcolato a 2n bit, prendendo i n bit meno significativi del risultato.		

Esempio	`__m128i a = _mm_set_epi32(4, 3, 2, 1);`
	`__m128i b = _mm_set_epi32(1, 2, 3, 4);`
	`__m128i c = _mm_mullo_epi32(a,b);  // c = [4, 6, 6, 4]`

`__m256i` **`_mm256_mullo_epi16`**`(__m256i a, __m256i b)` `__m256i` **`_mm256_mullo_epi32`**`(__m256i a, __m256i b)`			`__m256i * __m256i`
Opzione gcc	`-mavx2`	**Istruzione**	`vpmullw ymm, ymm, ymm` `vpmulld ymm, ymm, ymm`
Descrizione	Moltiplica gli elementi corrispondenti in `a` e `b` come vettori di `short` (`epi16`) o `int` (`epi32`) e restituisce il risultato. Ciascun prodotto di valori a n bit è calcolato a 2n bit, prendendo i n bit meno significativi del risultato.		

Esempio	`__m256i a = _mm256_set_epi32(4, 3, 2, 1, 4, 3, 2, 3);`
	`__m256i b = _mm256_set_epi32(1, 2, 3, 4, 2, 2, 0, 3);`
	`__m256i c = _mm256_mullo_epi32(a,b); // c = [4, 6, 6, 4, 8, 6, 0, 9]`		

Per altre versioni delle operazioni di moltiplicazione, come quelle in virgola mobile, si rimanda a [IntelIntr].

2.4.2 Minimo e massimo

Le operazioni di **minimo** sono del tutto analoghe a quelle che seguono, rimpiazzando `max` con `min`.

`__m128i` **`_mm_max_epi8`** `(__m128i a, __m128i b)`
`__m128i` **`_mm_max_epi16`**`(__m128i a, __m128i b)`
`__m128i` **`_mm_max_epi32`**`(__m128i a, __m128i b)`
`__m128i` **`_mm_max_epu8`** `(__m128i a, __m128i b)`
`__m128i` **`_mm_max_epu16`**`(__m128i a, __m128i b)`
`__m128i` **`_mm_max_epu32`**`(__m128i a, __m128i b)`
			`max(__m128i,__m128i)`

Opzione gcc	`-msse4.1`
	`-msse2` (`epu8`, `epi16`)
		Istruzione	`pmaxsb xmm, xmm`
			`pmaxsw xmm, xmm`
			`pmaxsd xmm, xmm`
			`pmaxub xmm, xmm`
			`pmaxuw xmm, xmm`
			`pmaxud xmm, xmm`

Descrizione	Calcola il massimo degli elementi corrispondenti in `a` e `b` come vettori di `char` (`epi8`), `short` (`epi16`), `int` (`epi32`), `unsigned char` (`epu8`), `unsigned short` (`epu16`), `unsigned int` (`epu32`), e restituisce il risultato.		

Esempio	`__m128i a = _mm_set_epi32(4, -3, 2, -1);`
	`__m128i b = _mm_set_epi32(1,  2, 3, -4);`
	`__m128i c = _mm_max_epi32(a,b);  // c = [4,  2, 3, -1]`
	`__m128i d = _mm_max_epu32(a,b);  // d = [4, -3, 3, -1]`		

`__m256i` **`_mm256_max_epi8`** `(__m256i a, __m256i b)`
`__m256i` **`_mm256_max_epi16`**`(__m256i a, __m256i b)`
`__m256i` **`_mm256_max_epi32`**`(__m256i a, __m256i b)`
`__m256i` **`_mm256_max_epu8`** `(__m256i a, __m256i b)`
`__m256i` **`_mm256_max_epu16`**`(__m256i a, __m256i b)`
`__m256i` **`_mm256_max_epu32`**`(__m256i a, __m256i b)`
			`max(__m256i,__m256i)`

Opzione `gcc`	`-mavx2`	**Istruzione**	`vpmaxsb ymm, ymm, ymm`
			`vpmaxsw ymm, ymm, ymm`
			`vpmaxsd ymm, ymm, ymm`
			`vpmaxub ymm, ymm, ymm`
			`vpmaxuw ymm, ymm, ymm`
			`vpmaxud ymm, ymm, ymm`

Descrizione	Calcola il massimo degli elementi corrispondenti in `a` e `b` come vettori di `char` (`epi8`), `short` (`epi16`), `int` (`epi32`), `unsigned char` (`epu8`), `unsigned short` (`epu16`), `unsigned int` (`epu32`), e restituisce il risultato.		

Esempio	`__m256i a = _mm256_set_epi32(4, -3, 2, -1, 4, -3, 2, -1);`
	`__m256i b = _mm256_set_epi32(1,  2, 3, -4, 1,  2, 3, -4);`
	`__m256i c = _mm256_max_epi32(a,b);  // c = [4,  2, 3, -1, ...]`
	`__m256i f = _mm256_max_epu32(a,b);  // c = [4, -3, 3, -1, ...]`		

Per altre operazioni si rimanda a [IntelIntr].

2.5 Tabella riassuntiva

Riassumiamo nella seguente tabella le operazioni viste nei paragrafi precedenti:

Copia da memoria a vettore (load)	
`__m128i` **`_mm_load_si128`** `(__m128i const* mem_addr)` `__m128i` **`_mm_loadu_si128`**`(__m128i const* mem_addr)`	array interi all. → `__m128i` array interi → `__m128i`
`__m256i` **`_mm256_load_si256`** `(__m256i const* mem_addr)` `__m256i` **`_mm256_loadu_si256`**`(__m256i const* mem_addr)`	array interi all. → `__m256i` array interi → `__m256i`
`__m128` **`_mm_load_ps`** `(float const* mem_addr)` `__m128` **`_mm_loadu_ps`**`(float const* mem_addr)`	`float[4]` allin. → `__m128` `float[4]` → `__m128`
`__m128d` **`_mm_load_pd`** `(double const* mem_addr)` `__m128d` **`_mm_loadu_pd`**`(double const* mem_addr)`	`double[2]` allin. → `__m128d` `double[2]` → `__m128d`

`__m256 _mm256_load_ps (float const* mem_addr)` `__m256 _mm256_loadu_ps(float const* mem_addr)`	`float[8]` allin. → `__m256` `float[8]` → `__m256`
`__m256d _mm256_load_pd (double const* mem_addr)` `__m256d _mm256_loadu_pd(double const* mem_addr)`	`double[4]` allin. → `__m256d` `double[4]` → `__m256d`
Copia da vettore a memoria (store)	
`void _mm_store_si128 (__m128i* mem_addr, __m128i a)` `void _mm_storeu_si128(__m128i* mem_addr, __m128i a)`	`__m128i` → array interi allin. `__m128i` → array interi
`void _mm256_store_si256 (__m256i* mem_addr, __m256i a)` `void _mm256_storeu_si256(__m256i* mem_addr, __m256i a)`	`__m256i` → array interi allin. `__m256i` → array interi
`void _mm_store_ps (float* mem_addr, __m128 a)` `void _mm_storeu_ps(float* mem_addr, __m128 a)`	`__m128` → `float[4]` allin. `__m128` → `float[4]`
`void _mm256_store_ps (float* mem_addr, __m256 a)` `void _mm256_storeu_ps(float* mem_addr, __m256 a)`	`__m256` → `float[8]` allin. `__m256` → `float[8]`
`void _mm_store_pd (double* mem_addr, __m128d a)` `void _mm_storeu_pd(double* mem_addr, __m128d a)`	`__m128d` → `double[2]` allin. `__m128d` → `double[2]`
`void _mm256_store_pd (double* mem_addr, __m256d a)` `void _mm256_storeu_pd(double* mem_addr, __m256d a)`	`__m256d` → `double[4]` allin. `__m256d` → `double[4]`
Addizione	

`__m128i _mm_add_epi8 (__m128i a, __m128i b)`
`__m128i _mm_add_epi16(__m128i a, __m128i b)`
`__m128i _mm_add_epi32(__m128i a, __m128i b)`
`__m128i _mm_add_epi64(__m128i a, __m128i b)`
	`char[16] + char[16]`
	`short[8] + short[8]`
	`int[4] + int[4]`
	`long[2] + long[2]`

`__m256i _mm256_add_epi8 (__m256i a, __m256i b)`
`__m256i _mm256_add_epi16(__m256i a, __m256i b)`
`__m256i _mm256_add_epi32(__m256i a, __m256i b)`
`__m256i _mm256_add_epi64(__m256i a, __m256i b)`
	`char[32] + char[32]`
	`short[16] + short[16]`
	`int[8] + int[8]`
	`long[4] + long[4]`

`__m128 _mm_add_ps(__m128 a, __m128 b)`	`float[4] + float[4]`
`__m128d _mm_add_pd(__m128d a, __m128d b)`	`double[2] + double[2]`
`__m256 _mm256_add_ps(__m256 a, __m256 b)`	`float[8] + float[8]`
`__m256d _mm256_add_pd(__m256d a, __m256d b)`	`double[4] + double[4]`
Prodotto	
`__m128i _mm_mullo_epi16(__m128i a, __m128i b)` `__m128i _mm_mullo_epi32(__m128i a, __m128i b)`	`short[8] * short[8]` `int[4] * int[4]`
`__m256i _mm256_mullo_epi16(__m256i a, __m256i b)` `__m256i _mm256_mullo_epi32(__m256i a, __m256i b)`	`short[16] * short[16]` `int[8] * int[8]`

Massimo	

`__m128i _mm_max_epi8 (__m128i a, __m128i b)`
`__m128i _mm_max_epi16(__m128i a, __m128i b)`
`__m128i _mm_max_epi32(__m128i a, __m128i b)`
`__m128i _mm_max_epu8 (__m128i a, __m128i b)`
`__m128i _mm_max_epu16(__m128i a, __m128i b)`
`__m128i _mm_max_epu32(__m128i a, __m128i b)`
	`max(char[16])`
	`max(short[8])`
	`max(int[4])`
	`max(unsigned char[16])`
	`max(unsigned short[8])`
	`max(unsigned int[4])`

`__m256i _mm256_max_epi8 (__m256i a, __m256i b)`
`__m256i _mm256_max_epi16(__m256i a, __m256i b)`
`__m256i _mm256_max_epi32(__m256i a, __m256i b)`
`__m256i _mm256_max_epu8 (__m256i a, __m256i b)`
`__m256i _mm256_max_epu16(__m256i a, __m256i b)`
`__m256i _mm256_max_epu32(__m256i a, __m256i b)`
	`max(char[32])`
	`max(short[16])`
	`max(int[8])`
	`max(unsigned char[32])`
	`max(unsigned short[16])`
	`max(unsigned int[8])`

2.5 Esempi

2.5.1 Somma vettoriale di array di dimensione arbitraria

Si vuole realizzare una funzione che, dati tre array `A`, `B` e `C` di `float` di dimensione n, calcola la somma vettoriale `C=A+B` utilizzando istruzioni AVX. Partiamo da una semplice versione sequenziale e vediamo come vettorizzarla:

```
void somma_float(const float* A, const float* B, float* C, size_t n) {
    long i;
    for (i=0; i<n; i++) C[i] = A[i] + B[i];
}
```

Usando istruzioni AVX, possiamo effettuare somme di 8 `float` alla volta impaccati in oggetti vettoriali di tipo `__m256`. Partiamo con una trasformazione del codice chiamata **loop unrolling parziale di ragione k**, che consiste nel ridurre di un fattore k il numero di iterazioni effettuando k operazioni per iterazione:

```
void somma_float(const float* A, const float* B, float* C, size_t n) {
    long i;
    for (i=0; i+7<n; i+=8) {             // loop unrolling di ragione 8
        C[i]   = A[i]   + B[i];
        C[i+1] = A[i+1] + B[i+1];
        C[i+2] = A[i+2] + B[i+2];
        C[i+3] = A[i+3] + B[i+3];
        C[i+4] = A[i+4] + B[i+4];
        C[i+5] = A[i+5] + B[i+5];
        C[i+6] = A[i+6] + B[i+6];
        C[i+7] = A[i+7] + B[i+7];
    }
    for (; i<n; i++) C[i] = A[i] + B[i]; // serve se 8 non divide n
}
```

Osserviamo che, se n non è divisibile per 8, non è possibile effettuare tutte le somme a 8 a 8. Un secondo ciclo effettua quindi le somme rimanenti, che sono al più 7.

Rimpiazziamo ora il corpo del primo ciclo con istruzioni vettoriali che effettuano la somma:

```
#include <immintrin.h>

void somma_float(const float* A, const float* B, float* C, size_t n) {
    long i;
```

```
    for (i=0; i+7<n; i+=8) {             // loop unrolling di ragione 8
        __m256 a = _mm256_loadu_ps(A+i); // copia A[i..i+7] in a
        __m256 b = _mm256_loadu_ps(B+i); // copia B[i..i+7] in b
        __m256 c = _mm256_add_ps(a,b);   // calcola c=a+b
        _mm256_storeu_ps(C+i, c);        // copia c in C[i..i+7]
    }
    for (; i<n; i++) C[i] = A[i] + B[i]; // serve se 8 non divide n
}
```

Possiamo testare il programma con un semplice main di prova:

```
int main() {
    long i;
    float A[17] = { 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16, 17 };
    float B[17] = { 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16, 17 };
    float C[17];
    somma_float((const float*)A, (const float*)B, C, 17);
    for (i=0; i<17; i++) printf("%f ", C[i]); // stampa 2 4 6 8 10 12 ...
    printf("\n");
}
```

Si noti che tutte le operazioni vettoriali utilizzate usano istruzioni AVX, pertanto possiamo usare l'opzione `-mavx`. Compiliamo con `gcc somma_float.c -o somma_float -O1 -mavx` ed eseguiamo con `./somma_float`.

Approfondimento.

E' interessante analizzare il codice assembly generato con `gcc somma_float.c -S -O1 -mavx` (gcc versione 4.8.4 in Ubuntu). Il codice del loop vettorizzato è:

```
.L15:
      vmovups (%rdi,%rax), %ymm1
      vmovups (%rsi,%rax), %ymm0
      vaddps %ymm0, %ymm1, %ymm0
      vmovups %ymm0, (%rdx,%rax)
      addq $8, %r8
      addq $32, %rax
      cmpq %r9, %r8
      jne .L15
```

dove `%rdi` è `A`, `%rsi` è `B`, `%rdx` è `C`, `%r8` è `i` ed `%r9` è `n`.

2.5.2 Prodotto scalare di array di dimensione arbitraria

Si vuole realizzare una funzione che, dati due array `A`, `B` di `int` di dimensione n, calcola il prodotto scalare $s=A \cdot B$ utilizzando istruzioni AVX. Partiamo da una semplice versione sequenziale e vediamo come vettorizzarla:

```
int prods_int(const int* A, const int* B, size_t n) {
    long i;
    int s = 0;
    for (i=0; i<n; i++) s += A[i] * B[i];
    return s;
}
```

Usando istruzioni AVX, Procediamo con il loop unrolling come mostrato nel paragrafo 2.5.1:

```
int prods_int(const int* A, const int* B, size_t n) {
    long i;
    int s[8] = { 0 };              // array s inizializzato a zero
    for (i=0; i+7<n; i+=8) {       // loop unrolling parziale di ragione 8
        s[0] += A[i]   * B[i];
        s[1] += A[i+1] * B[i+1];
        s[2] += A[i+2] * B[i+2];
        s[3] += A[i+3] * B[i+3];
        s[4] += A[i+4] * B[i+4];
        s[5] += A[i+5] * B[i+5];
        s[6] += A[i+6] * B[i+6];
        s[7] += A[i+7] * B[i+7];
    }
    for (; i<n; i++) s[0] += A[i] * B[i];   // serve se 8 non divide n
    return s[0]+s[1]+s[2]+s[3]+s[4]+s[5]+s[6]+s[7];
}
```

La costruzione mostrata usa un vettore di appoggio di 8 `int` per calcolare le somme parziali, dove `s[0]` contiene le somme dei prodotti degli elementi di `A` e `B` con indice i tale che i % 8 == 0, `s[1]` quelle degli elementi con i % 8 == 1, ecc. Gli elementi rimanenti considerati nel secondo ciclo vengono accumulati in `s[0]`.

Così formulato, il codice si vettorizza direttamente come segue:

```
#include <immintrin.h>

int prods_int(const int* A, const int* B, size_t n) {
    long i;
    int s[8] __attribute__((aligned(32))) = { 0 };
    __m256i a, b, c, d = _mm256_load_si256((const __m256i*)s); // copia s in d

    for (i=0; i+7<n; i+=8) {  // loop unrolling di ragione 8
        a = _mm256_loadu_si256((const __m256i*)(A+i)); // copia A[i..i+7] in a
        b = _mm256_loadu_si256((const __m256i*)(B+i)); // copia B[i..i+7] in b
        c = _mm256_mullo_epi32(a,b);                   // c=a*b
        d = _mm256_add_epi32(c,d);                     // d=d+c
    }
    _mm256_store_si256((__m256i*)s, d);                // copia d in s
    for (; i<n; i++) s[0] += A[i] * B[i];
    return s[0]+s[1]+s[2]+s[3]+s[4]+s[5]+s[6]+s[7];
}
```

Poiché **non abbiamo alcuna garanzia** che gli array `A` e `B` siano allineati a indirizzi multipli di 32, dobbiamo utilizzare istruzioni load che **non richiedono allineamento** (`_mm256_loadu_si256`). Allineiamo invece l'array `s` usando la direttiva `__attribute__((aligned(32)))`, così possiamo usare la `_mm256_load_si256` che richiede allineamento[2].

Per un test, possiamo usare il seguente semplice programma di prova:

```
int main() {
    int A[17] = { 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16, 17 };
    int B[17] = { 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16, 17 };

    int s = prods_int((const int*)A, (const int*)B, 17);

    printf("%d\n", s); // stampa 1785
    return 0;
}
```

Poiché l'operazione `_mm256_mullo_epi32` è disponibile solo in AVX2, compiliamo con `gcc prods_int.c -O1 -mavx2 -o prods_int`.

[2] La cosa è tuttavia praticamente irrilevante a livello prestazionale, poiché la load da `s` è esterna al ciclo.

Bibliografia

[IntelIntr] The Intel Intrinsics Guide
https://software.intel.com/sites/landingpage/IntrinsicsGuide/ (verificato 5 gennaio 2016)

[PosixMemalign] The Open Group Base Specifications Issue 7, `posix_memalign`
http://pubs.opengroup.org/onlinepubs/9699919799/functions/posix_memalign.html
(verificato 5 gennaio 2016)

[GNUMemalign] The GNU standard library: Allocating Aligned Memory Blocks
http://www.gnu.org/software/libc/manual/html_node/Aligned-Memory-Blocks.html
(verificato 5 gennaio 2016)